

UNIVERSIDADE FEDERAL DO PARANÁ

JEFFERSON SATOSHI KATO

RACIONALIDADE LIMITADA, FORMAÇÃO DE GRUPOS E A EVOLUÇÃO DA
CONFIANÇA: UM MODELO ECONÔMICO BASEADO EM AGENTES

CURITIBA

2018

JEFFERSON SATOSHI KATO

RACIONALIDADE LIMITADA, FORMAÇÃO DE GRUPOS E A EVOLUÇÃO DA
CONFIANÇA: UM MODELO ECONÔMICO BASEADO EM AGENTES

Dissertação apresentada ao Programa de Pós-graduação em Desenvolvimento Econômico, Área de concentração em Economia Comportamental do Departamento de Economia da Universidade Federal do Paraná, Setor de Ciências Sociais Aplicadas, como parte dos requisitos para a obtenção do título de mestre em desenvolvimento econômico.

Orientadora: Profª. Dra. Adriana Sbicca

CURITIBA

2018

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA DE CIÊNCIAS
SOCIAIS APLICADAS – SIBI/UFPR COM DADOS FORNECIDOS PELO(A)
AUTOR(A)

Kato, Jefferson Satoshi

Racionalidade limitada, formação de grupos e a evolução da confiança:
um modelo econômico baseado em agentes / Jefferson Satoshi Kato . –
2018.

51 p.

Orientadora: Adriana Sbicca.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de
Ciências Sociais Aplicadas, Programa de Pós-Graduação em
Desenvolvimento Econômico.

Defesa: Curitiba, 2018.

1. Racionalidade limitada. 2. Simulação baseada em agentes. 3.
Confiança. 4. Economia comportamental. I. Fernandes, Adriana Sbicca, 1969-
II. Universidade Federal do Paraná. Setor de Ciências Sociais Aplicadas.
Programa de Pós-Graduação em Desenvolvimento Econômico. III. Título.

CDD 330.019



MINISTÉRIO DA EDUCAÇÃO
SETOR CIÊNCIAS SOCIAIS APLICADAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO DESENVOLVIMENTO
ECONÔMICO

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em DESENVOLVIMENTO ECONÔMICO da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **JEFFERSON SATOSHI KATO**, intitulada: **RACIONALIDADE LIMITADA, FORMAÇÃO DE GRUPOS E A EVOLUÇÃO DA CONFIANÇA: UM MODELO ECONÔMICO BASEADO EM AGENTES**, após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de Mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 27 de Fevereiro de 2018.


ADRIANA SBICCA FERNANDES(UFPR)
(Presidente da Banca Examinadora)


RAMON VICENTE GARCIA FERNANDEZ(UFABC)


JOÃO BASÍLIO PEREIMA NETO(UFPR)

RESUMO

A confiança tem papel importante nos resultados de transações econômicas e no desempenho econômico. É possível modelar a confiança através de jogos do investimento, onde um jogador, na expectativa de uma recompensa ou de um resultado melhor, assume um determinado risco mediante a ação futura do outro jogador. A teoria dos jogos tradicional não prevê a existência de confiança quando os jogadores apresentam comportamento maximizador e egoísta. Entretanto, experimentos feitos com esses jogos revelaram a presença de confiança nas decisões dos jogadores. Essa dissertação tem como objetivo construir um modelo econômico baseado em agentes onde as decisões são as mesmas do jogo do investimento e, com isso, contribuir para a discussão quanto aos fatores associados à emergência da confiança em uma população. Aprendizado, seleção natural e formação de grupos serão introduzidos no modelo para verificar seu impacto individual e conjunto na emergência da confiança entre os agentes. A modelagem busca não condicionar o comportamento dos agentes como maximizador e egoísta e assim, torná-lo mais realista, semelhante ao observado nos experimentos. Por isso os agentes serão construídos com racionalidade limitada. A racionalidade limitada, por sua vez, é modelada através de um algoritmo de inteligência artificial, o *Learning Classifier System* (LCS). A seleção natural tende a favorecer um comportamento mais egoísta. Já o aprendizado e a formação de grupos são fatores que aumentam a confiança nos modelos e conseguem reverter a tendência egoísta ao serem introduzidos junto com a seleção natural.

Palavras-chave: Confiança. Jogos de Investimento. Racionalidade limitada. Simulação baseada em agentes.

ABSTRACT

Trust has an important role in the outcomes of economic transactions and the economic development. It is possible to model trust by an investment game, where a player, facing a reward or a better outcome, takes a certain risk of the defection of another player. The traditional game theory does not predict the existence of trust by players that are selfish and have maximizing behavior. However, experiments with these games reveal the presence of trust in the decision of players. This dissertation aims to build an agent-based economic model where the decisions are the same as in the investment game and contribute to the discussion about the factors associated with trust in a population. Learning, natural selection and group formation are introduced in the model to verify their impact in the emergence of trust by the agents. The modelling does not condition the agents' behavior in a selfish maximizing way and by doing so approaches a more realistic one, similar to that observed in experiments. So the agents are built with bounded rationality. Bounded rationality is modelled through an artificial intelligence algorithm, the Learning Classifier System (LCS). The natural selection tends to favor a more selfish behavior. On the other hand, leaning and group formation tend to increase trust in the models and are able to reverse the selfish behavior when introduced along with natural selection.

Keywords: Trust. Investment games. Bounded rationality. Agent-based simulation.

SUMÁRIO

1.	INTRODUÇÃO.....	7
2.	CONFIANÇA NAS TRANSAÇÕES ECONÔMICAS E EXPERIMENTOS.....	9
2.1.	EXPERIMENTOS COM JOGOS DO INVESTIMENTO	10
2.2.	ALTRUÍSMO, CONFIANÇA E RECIPROCIDADE.....	12
2.3.	VÍNCULOS	13
2.4.	RELAÇÃO SOCIAL	16
3.	RACIONALIDADE LIMITADA E LEARNING CLASSIFIER SYSTEM.....	18
4.	MODELO DE CONFIANÇA EM UMA SIMULAÇÃO BASEADA EM AGENTES	22
4.1.	CONSTRUINDO UM MUNDO ARTIFICIAL.....	23
4.2.	SELEÇÃO	25
4.3.	REGRAS DE DECISÃO	26
4.4.	FORMAÇÃO DE GRUPOS E SELEÇÃO MULTINÍVEL.....	28
4.5.	DECISÕES DOS AGENTES NA SIMULAÇÃO	29
5.	MODELO GENERATIVO, AVALIAÇÃO DE FATORES E RESULTADOS	33
5.1.	MODELO BASE	36
5.2.	APRENDIZADO.....	38
5.3.	SELEÇÃO	39
5.4.	FORMAÇÃO DE GRUPOS	41
5.5.	VALIDAÇÃO COM DADOS REAIS.....	43
6.	CONCLUSÕES.....	46
	REFERÊNCIAS	49
	APÊNDICE I – ALGORITMO LEARNING CLASSIFIER SYSTEM (LCS)	51

1. INTRODUÇÃO

A confiança tem papel importante no desempenho econômico ao facilitar as transações econômicas tornando-as mais ágeis e menos burocráticas. Na economia, a confiança pode ser detectada em transações que envolvam algum tipo de empréstimo sem garantia formal de um indivíduo, o Investidor, para outro, o Parceiro. Esse bem ou montante emprestado gera um aumento de utilidade para o Parceiro que, num momento posterior, retorna ao Investidor o bem ou montante emprestado por ele junto com um valor correspondente a um percentual desse aumento de utilidade obtido.

Ao se analisar essas transações pela teoria dos jogos tradicional onde se assume que os jogadores desejam maximizar seus ganhos, o Parceiro tem uma estratégia dominante que consiste em manter o bem ou montante recebido do Investidor, dado que o empréstimo foi informal e sem garantia. Sua utilidade é correspondente ao valor desse bem ou montante mais o aumento de utilidade que ele proporciona. Antecipando o movimento do Parceiro, a estratégia do Investidor consiste em não emprestar nada, dado que qualquer bem ou montante emprestado seria mantido por ele. Essa seria a previsão do equilíbrio de Nash pela teoria dos jogos tradicional.

Porém, em experimentos feitos para verificar empiricamente as decisões feitas pelos participantes em jogos como o descrito acima, verifica-se que existem fatores comportamentais que interferem nesse mecanismo e que trazem resultados diferentes do que a teoria tradicional prevê. Esses experimentos mostram que mesmo em condições de anonimato e sem nenhuma garantia formal, os Investidores fazem empréstimos aos Parceiros e esses costumam retornar algum valor para os Investidores.

Nesses experimentos, ao se alterar algumas características da sua estrutura, como por exemplo, os vínculos existentes entre os jogadores ou as informações que eles têm a respeito de resultados anteriores, os pesquisadores conseguem explicar quais fatores aumentam ou diminuem a confiança entre os participantes e assim contribuem para o entendimento desse comportamento.

Outra abordagem de pesquisa que também auxilia o entendimento da confiança entre indivíduos é a simulação baseada em agentes. Ao construir um modelo baseado em agentes, pode-se entender como a confiança pode emergir através de um conjunto simples de premissas, regras comportamentais e processos decisórios. Além disso, também é possível entender como alterações nesse conjunto de premissas e regras afetam ou não a emergência da confiança entre os agentes. Enquanto que nos experimentos é possível analisar as

características dos indivíduos e sua influência na confiança, as simulações permitem analisar regras mais estruturais de formação desses indivíduos, como por exemplo, aprendizado, seleção natural e formação de grupos que são mais difíceis de serem analisadas através de experimentos.

Porém, ao se utilizar um modelo econômico baseado em agentes, surge o desafio de modelar a decisão dos agentes desse modelo de forma a evitar que seu comportamento reflita as decisões racionais que a teoria dos jogos tradicional prevê e que passe a refletir o comportamento mais realista observado nos experimentos. Além disso, é necessário que essa modelagem seja também realista e reflita a forma como as pessoas tomam as decisões no dia a dia. Opta-se, portanto, pelo uso do algoritmo de inteligência artificial *Learning Classifier System* (LCS) pela sua similaridade com a teoria da racionalidade limitada que descreve melhor o processo de decisão das pessoas.

Essa dissertação tem como objetivo construir um modelo econômico baseado em agentes onde as decisões são as mesmas dos experimentos e, com isso, contribuir para a discussão quanto aos fatores associados à emergência da confiança em uma população. Para isso o trabalho foi estruturado da seguinte forma: A seção 2 detalha o conceito de confiança usado na dissertação e descreve o modelo do jogo do investimento usado nos experimentos e no modelo econômico baseado em agentes. Também descreve alguns experimentos que indicam a existência de confiança e que apontam os fatores que podem influenciar a confiança entre os participantes. A seção 3 aponta as similaridades entre as teorias da racionalidade limitada e do *satisficing* com o algoritmo de inteligência artificial LCS usado tanto para modelar a racionalidade dos agentes na simulação, como também para contornar o uso do raciocínio dedutivo na decisão dos agentes o que possivelmente traria previsões parecidas com as da teoria dos jogos tradicional. A seção 4 aponta as vantagens de se utilizar um modelo econômico baseado em agentes e descreve o modelo usado para a modelagem da confiança. A seção 5 traz os resultados e a seção 6 conclui.

2. CONFIANÇA NAS TRANSAÇÕES ECONÔMICAS E EXPERIMENTOS

Em seu artigo para a Forbes, Hartford (2006) exemplifica como seria um mundo sem confiança. “Imagine ir a uma loja na esquina comprar uma caixa de leite e se deparar com o refrigerador trancado. Após convencer o dono da loja a retirar o leite do refrigerador, você acaba então tendo que discutir se você vai entregar o dinheiro primeiro, ou se ele vai entregar o leite primeiro. Você finalmente consegue convencê-lo a realizar uma troca simultânea. Um gostinho de vida num mundo sem confiança – agora imagine tentar conseguir uma hipoteca.”

Transações econômicas em que um agente confia nas ações futuras de outros são executadas com custo menor em sociedade com alto grau de confiança (Knack e Keefer, 1997). A confiança e as normas sociais seriam, portanto um lubrificante do sistema social (Arrow 1974).

Knack e Keefer (1997) mostram em seu estudo como métricas de confiança e senso cívico, levantadas através de uma pesquisa do *World Values Surveys*¹ em vários países, estão correlacionadas com o crescimento econômico per capita de longo prazo. Em uma sociedade onde existe mais confiança as pessoas gastam menos tempo tentando se proteger de serem exploradas em transações comerciais. A falta de confiança pode desencorajar a inovação. Além disso, mercados de crédito informal podem ser uma importante fonte de desenvolvimento, porém só podem existir em ambientes de alta confiança. Sociedades com alta confiança também fazem investimentos de prazos mais longos.

Fukuyama (1995) afirma que “o bem estar das nações, além de sua habilidade de competir, está condicionada por uma característica cultural simples e universal: o nível de confiança inerente de uma sociedade”. De acordo com Fukuyama, “confiança é a expectativa que surge dentro de uma comunidade com comportamento regular, honesto e cooperativo, baseado nas mesmas normas compartilhadas, a respeito da outra parte dos membros dessa comunidade”.

¹ O World Values Surveys contém dados de pesquisas feitas com milhares de respondentes de 57 países feito ao longo de seis rodadas. Na época em que o trabalho de Knack e Keefer foi feito, havia apenas duas rodadas totalizando na época 29 países. A questão usada para levantar a métrica de confiança foi: “De forma geral, você diria que a maioria das pessoas é confiável ou que é necessário ter cuidado ao lidar com as pessoas?”. A métrica de confiança é o percentual de pessoas que responderam que “a maioria das pessoas é confiável” após desconsiderar as respostas “não sei”. Já a força das normas sociais é levantada pelas respostas a respeito de se os seguintes comportamentos “são sempre aceitáveis, nunca são aceitáveis, ou algo no meio”: a) “requeritar benefícios do governo quando não se têm direito a eles”, b) “não pagar tarifa de transporte público”, c) “sonegar impostos se tiver a chance”, d) “ficar com dinheiro encontrado” e e) “não reportar dano que você fez acidentalmente a um veículo estacionado”. As respostas para cada item são dadas em uma escala de 1 (nunca é aceitável) até 10 (sempre aceitável). As escalas foram invertidas para que os maiores números refletissem maior cooperação e somadas em uma escala total de 50 pontos.

De acordo com Cox (2004), a confiança pode ser definida como uma expectativa de aumento de ganho ou de utilidade que um agente denominado Investidor tem ao executar uma ação, mas que o expõe a um risco mediante a possibilidade de deslealdade de outro agente denominado Parceiro. Analogamente, a reciprocidade pode ser definida como a preferência manifestada pelo agente Parceiro por um ganho ou utilidade maior do agente Investidor mediante redução de seu próprio ganho ou utilidade como consequência da manifestação de confiança em uma ação prévia do agente Investidor. Ou seja, na ausência de uma ação com confiança do agente Investidor, as preferências do agente Parceiro seriam por um resultado menor para o agente Investidor e maior para si. Serão estes os conceitos de confiança e reciprocidade utilizados na dissertação.

Além de confiança e reciprocidade, é necessário conceituar o altruísmo. Ainda conforme Cox (2004), o altruísmo pode ser definido como uma “preferência alheia” positiva. “Preferência alheia” pode ser definida como a preferência que uma pessoa tem pelo benefício ou ganho de outra pessoa além do seu próprio. Ou seja, sendo y^j o ganho do agente j e assumindo que as preferências podem ser representadas por uma função utilidade, o agente k possui “preferência alheia” se sua função de utilidade $u^k(y^k, y^j)$ não for uma função constante de y^j . Portanto um agente manifesta altruísmo se resultados onde o ganho do outro agente é maior alteram positivamente sua preferência.

Um fator que diferencia a confiança do altruísmo seria o fator de risco associado ao primeiro e que inexistente no segundo. Da mesma forma, um fator que diferencia a reciprocidade do altruísmo seria a existência de uma ação prévia no caso da reciprocidade. É importante notar que vários fatores podem fazer parte de uma decisão e, portanto, um mesmo comportamento pode apresentar tanto confiança como também altruísmo ou, também, um mesmo comportamento pode apresentar tanto reciprocidade como também altruísmo.

2.1. EXPERIMENTOS COM JOGOS DO INVESTIMENTO

As transações descritas acima podem ser modeladas em um jogo do investimento conforme proposto por Berg, Dickhaut e McCabe (1995). Nesse jogo, um Investidor recebe uma quantia X . O Investidor deve então decidir dividir uma quantia T ($0 \leq T \leq X$) com um Parceiro ficando com o valor $X - T$. O Parceiro tem um rendimento em cima do valor recebido correspondente a uma taxa r e seu montante total passa a ser $(1 + r) \times T$. Por sua vez o Parceiro deve decidir que valor Y ($0 \leq Y \leq (1 + r) \times T$) desse montante deve manter

consigo, retornando ao Investidor o valor $(1 + r) \times T - Y$. O jogo finaliza e o Investidor fica no final com o valor de $X + rT - Y$.

No experimento de Berg, Dickhaut e McCabe (1995) um grupo de Investidores recebeu cada um \$10 em dez cédulas de \$1. Eles então deveriam decidir individualmente quantas cédulas deveriam colocar em um envelope que seria distribuído ao grupo de Parceiros ficando com o valor remanescente. Cada indivíduo do grupo de Parceiros recebeu um envelope com quantia enviada multiplicada por 3 também em cédulas de \$1. Cada Parceiro então decidiu quantas cédulas eles deveriam enviar para o mesmo Investidor com o qual ele foi pareado ficando com o valor restante.

Por exemplo, um Investidor recebeu \$10 ($X = \10) e decidiu enviar ao Parceiro \$5 ($T = \5) ficando com \$5 para si ($X - T = \5). Esse Parceiro teve o montante multiplicado por 3 ($r = 2$) e recebeu a quantia de \$15 ($[1 + r] \times T = [1 + 2] \times \$5 = \$15$). Ele decidiu então manter consigo o valor de \$10 ($Y = \10) e retornou ao Investidor \$5 ($[1 + r] \times T - Y = [1 + 2] \times \$5 - \$10 = \5). O jogo então finaliza com o Investidor ficando com o valor de \$10 no total ($X + rT - Y = \$10 + 2 \times \$5 - \$10 = \10).

Pela teoria dos jogos, usando o raciocínio na ordem cronológica inversa, a estratégia do Parceiro seria maximizar seu montante final. Considerando que esse Parceiro é racional e egoísta, ele escolheria ficar com todo o valor não retornando nada ao Investidor. Ou seja, o Parceiro não apresenta nenhuma reciprocidade, pois ele não manifesta preferência por um montante maior para o agente Investidor mediante redução de seu próprio montante como consequência da ação prévia do agente Investidor.

Num passo anterior, a estratégia do Investidor seria maximizar seu montante final. Tendo em mente a estratégia do Parceiro de maximizar seu resultado, o Investidor, que também é racional e egoísta, escolhe $T = 0$ ficando com o valor total X , não enviando nenhum valor ao Parceiro. Ou seja, o Investidor não apresenta confiança, pois ele não apresenta expectativa de aumento do seu montante ao enviar uma parte dele ao Parceiro, se expondo a um risco pela possibilidade de deslealdade do mesmo.

Sendo assim, neste jogo que é construído com agentes maximizadores e egoístas, não haveria nenhuma transação e eles terminariam o jogo com os montantes definidos inicialmente. Entretanto, vários experimentos feitos com jogos do investimento mostram que fatores comportamentais influenciam as decisões do Investidor e do Parceiro nesses jogos. As subseções seguintes trazem a descrição de alguns desses experimentos agrupados pelos fatores comportamentais analisados em cada um deles.

2.2. ALTRUÍSMO, CONFIANÇA E RECIPROCIDADE

Num jogo do investimento a decisão do Parceiro se assemelha muito à decisão de um Ditador no jogo do ditador. Neste jogo, um indivíduo, o Ditador, recebe uma quantia X e deve decidir qual parte dessa quantia deve repartir com outro indivíduo, o Recebedor, ao qual não cabe nenhum poder de decisão, apenas aceitar o que o Ditador propõe. Caso o Ditador queira maximizar seu montante deve decidir não repartir nada com o Recebedor. Porém, da mesma forma que no jogo do investimento, outros fatores além do montante final influenciam a decisão do Ditador.

Num experimento de Kahneman, Knetsch e Thaler (1986) com um jogo do ditador elaborado para obter uma indicação de prevalência de equidade não forçada em transações anônimas, estudantes de psicologia da Universidade de Cornell receberam a instrução para dividir a quantia de \$20 com um estudante anônimo da mesma classe sem possibilidade de rejeição pelo recebedor. A alocação poderia ser feita escolhendo entre duas possibilidades, uma divisão de \$18 para si mesmo e \$2 para o outro indivíduo ou \$10 para cada um. Foram tomadas as devidas precauções para garantir a privacidade dos participantes. Os resultados mostraram que as alocações iguais foram observadas mesmo sob a condição de completo anonimato e sem possibilidades de retaliação. Dos 161 estudantes, 122 (76%) optaram por uma divisão igualitária do montante.

Comparações entre decisões de Parceiros em jogos do investimento com decisões de Ditadores em jogos do ditador mostram que essas decisões se assemelham muito indicando que a decisão dos Parceiros está mais relacionada ao altruísmo do que à reciprocidade ao investimento do Investidor. Um experimento de Cox (2004) propôs separar quanto do valor enviado pelo Investidor se refere à confiança e o quanto se refere ao altruísmo. Além disso, também propôs separar o quanto do valor retornado pelo Parceiro se refere à reciprocidade e quanto também se refere ao altruísmo.

Nesse experimento foram feitos três tratamentos. O tratamento A é um jogo do investimento nos mesmos moldes de Berg, Dickhaut e McCabe (1995). Um Investidor deve decidir qual parcela dos \$10 deve enviar ao Parceiro. Essa quantia é multiplicada por 3 e o Parceiro deve decidir qual parcela desse montante deve retornar ao Investidor. O tratamento B é um jogo do ditador, onde o Ditador deve decidir qual parcela dos \$10 deve enviar ao Recebedor, sem nenhuma possibilidade de ele recusar ou retaliar. O tratamento C segue os mesmos moldes do jogo do investimento exceto pelo fato de que não cabe ao Investidor decidir qual parcela dos \$10 deve enviar ao Parceiro. Esse valor é estabelecido com base nos

valores obtidos pelas decisões dos Investidores no tratamento A. Com base nesses montantes, que também foram multiplicados por 3, o Parceiro do tratamento C deve decidir qual parcela deve retornar ao Investidor do tratamento C.

Como no tratamento B não cabe nenhuma decisão ao Recebedor, pode-se afirmar que a decisão do Ditador se refere estritamente ao altruísmo. Se o valor que foi enviado pelo Investidor no tratamento A for igual ao valor enviado pelo Ditador no tratamento B, pode-se afirmar que a decisão do Investidor se deve estritamente ao altruísmo e não à confiança no retorno que o Parceiro irá fazer. Por outro lado, se esse valor for maior, a diferença entre o valor enviado pelo Investidor e o valor enviado pelo Ditador pode ser classificada como devido à confiança.

Os resultados mostram que a média dos valores enviados pelos Investidores no tratamento A foi de \$5,97 e a média dos valores enviados pelos Ditadores no tratamento B foi de \$3,63. A diferença entre os valores nos dois tratamentos, \$2,34 é significativamente maior que \$0. Ou seja, há indício de que uma parte do valor enviado pelos Investidores se deve à confiança, porém outra parte pode ser atribuída ao altruísmo por parte dos Investidores.

No tratamento C o valor que o Parceiro recebe não está vinculado à decisão do Investidor deste tratamento e sim definido com base no valor da decisão do Investidor do tratamento A. Portanto a decisão do Parceiro não está associada à reciprocidade pela decisão do Investidor e, portanto pode-se afirmar que sua decisão se deve também estritamente ao altruísmo.

Os resultados mostram que a média dos valores recebidos pelos Investidores no tratamento A foi de \$4,94 e no tratamento C a média dos valores recebidos foi de \$2,06. A diferença entre os valores nos dois tratamentos, \$ 2,88 é significativamente maior que zero. Ou seja, da mesma forma que na decisão dos Investidores, há indício que parte do valor retornado pelos Parceiros se deve à reciprocidade, porém outra parte pode ser atribuída também ao altruísmo.

2.3. VÍNCULOS

O vínculo existente entre Investidor e Parceiro tem forte relevância nas decisões de investimento e retorno no jogo do investimento. Amigos e colegas compartilham uma grande experiência de interações emocionais, físicas e econômicas entre si além de conhecerem também o histórico de decisões um do outro com relação a terceiros. A falta de reciprocidade

dentro de um relacionamento pode implicar o rompimento desse vínculo causando um efeito de sanção para a parte desleal.

Além do vínculo direto, a existência de uma rede de relacionamentos pode aumentar a efetividade das sanções. Coleman (1988) dá exemplos de como o contexto social em que um indivíduo se encontra altera a confiança que ele deposita em outro indivíduo. No mercado atacadista de diamantes em Nova York, um comerciante entrega um pacote de pedras a outro comerciante para que este possa avaliá-las sem nenhuma garantia formal de que ele não vá substituir uma pedra por outra de valor inferior ou uma falsificação. Essa dinâmica traz eficiência e é de grande importância para o funcionamento desse mercado que é formado por judeus com alto grau de casamento entre seus familiares e com todos seus integrantes vivendo na mesma comunidade no Brooklyn. Caso um comerciante roube uma pedra ele perderia a família, religião e laços comunitários.

Karlan et al (2009) construíram um modelo teórico de como os vínculos sociais podem servir como colateral para empréstimos informais. Esse modelo mostra que vínculos mais fortes possibilitam maiores valores de empréstimos.

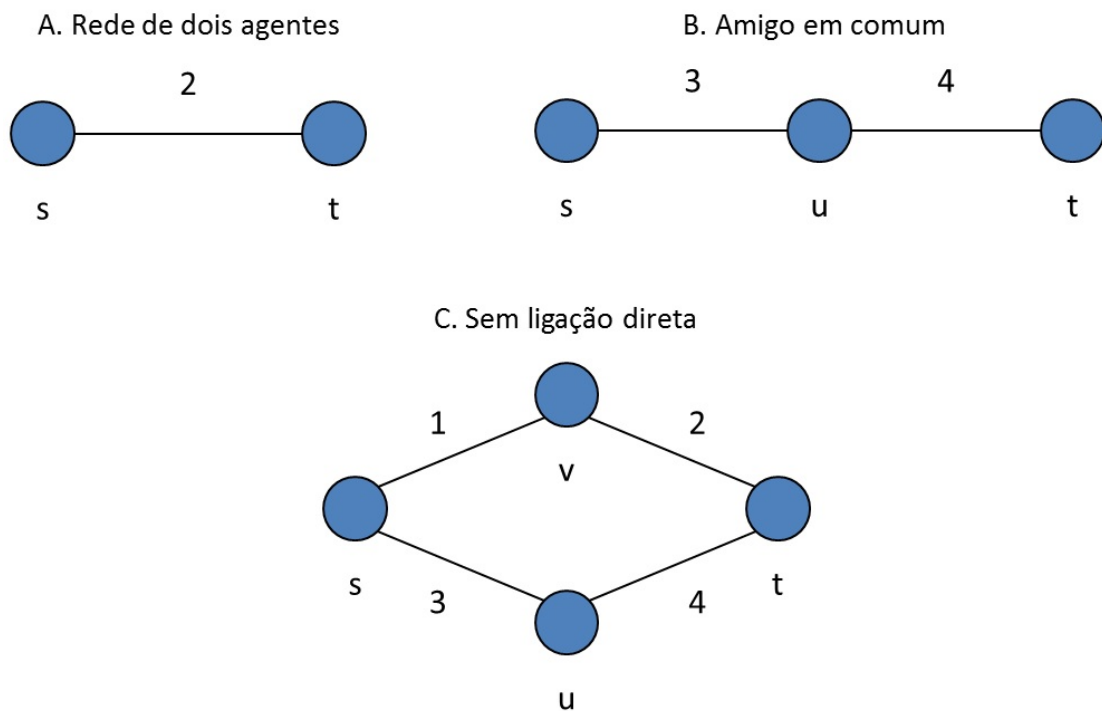
A Figura 1 mostra uma representação gráfica de vínculos sociais entre agentes. Na Figura 1-A a rede consiste de apenas dois agentes, s e t , que têm um vínculo direto entre si. Os vínculos são representados por um traço ligando os dois agentes e um valor que representa os benefícios da amizade ou o valor presente das futuras transações entre eles. No caso da Figura 1-A os agentes s e t têm um vínculo de valor 2.

Neste caso, esse vínculo permite empréstimos informais entre eles de valores que não excedam o valor atribuído à amizade entre eles, ou seja, limitados a 2.

Na Figura 1-B temos dois agentes s e t que não possuem vínculo direto entre si, porém possuem um amigo em comum u . O agente u tem um vínculo direto com o agente s ao qual eles atribuem o valor 3 e com o agente t ao qual eles atribuem o valor 4. Como o vínculo de menor valor entre eles tem valor 3, essa rede social permite empréstimos informais entre s e t de valor até 3. A lógica aqui seria de que u serviria de “fiador” para empréstimos feitos entre s e t . Se o devedor não devolver o empréstimo, ele perderia a amizade com u e o benefício de sua amizade.

Além disso, caso esses dois indivíduos possuam mais de um vínculo indireto, os valores desses vínculos se somam. Na Figura 1-C os agentes s e t também não possuem vínculo direto entre si, porém possuem dois amigos em comum, u e v . Nesse caso, a ligação indireta por u tem valor mínimo de 3 e a ligação indireta por v tem valor mínimo de 1 e essa rede possibilita empréstimos informais entre s e t de valor até $4 = 3 + 1$.

Figura 1 - Exemplos de redes sociais



Nota: Cada círculo representa um agente. Um traço ligando dois agentes representa um vínculo entre eles. O número próximo ao vínculo representa o valor associado a esse vínculo.

Fonte: Baseado em Karlan et al (2009)

Para mostrar a validade deste modelo, ele foi testado usando dados coletados em duas comunidades de baixa renda no Peru. Esses dados continham informações sobre as redes sociais dos indivíduos (quem faz parte da sua rede social, quanto tempo esses indivíduos passam juntos para estimar o valor do vínculo social, além de dados demográficos) e dados de empréstimos informais que foram feitos entre amigos, parentes e conhecidos. Os resultados mostram que a capacidade de empréstimo está correlacionada com o valor de vínculo social estimado entre dois indivíduos, além de mostrar que redes sociais mais densas permitem valores maiores de empréstimos informais.

Outro estudo que mostra que o valor do vínculo entre indivíduos especificamente em jogos do investimento é o de Bapna et al (2011), onde os participantes foram escolhidos através do Facebook e o vínculo entre eles foi medido diretamente pela rede social. Esse estudo mostra que a média dos valores enviados e retornados foram maiores entre conhecidos (\$7,79 e \$8,12 respectivamente) do que entre anônimos (\$5,62 e \$6,71 respectivamente) na rede social. Além disso, o lucro médio tanto do Investidor como do Parceiro foram maiores entre conhecidos (\$12 e \$14 respectivamente) do que entre anônimos (\$11,08 e \$10,17 respectivamente).

2.4. RELAÇÃO SOCIAL

Outro aspecto que influencia a decisão do Investidor é qual a informação que ele tem a respeito da prática de confiança dentro de um grupo. No experimento de Berg, Dickhaut e McCabe (1995) foi feita outra rodada de jogos do investimento, porém, para esse grupo foi apresentado um resumo com os resultados da primeira rodada como a quantidade de indivíduos por valor investido, o valor médio retornado e o valor médio de lucro (valor médio retornado menos o valor médio enviado).

Os resultados mostraram que esse relatório teve pouco efeito no valor médio enviado, de \$5,16 na rodada sem história para \$5,36 na rodada com história, porém essa diferença não é significativa. Entretanto, houve um grande aumento da dispersão dos valores enviados. Já com relação ao valor retornado, houve aumento de \$4,66 na rodada sem história para \$6,46 na rodada com história. O fator mais importante é que a apresentação da história social faz com que apareça uma correlação entre o valor enviado e o valor retornado.

Se por um lado a história social tem influência nas decisões dos agentes nos jogos do investimento, espera-se que os resultados desses jogos possam ter influência nos próprios agentes. O experimento de van Dijk et al (2002) procura medir como o sucesso em jogos de investimento em bem público, que são bem parecidos com jogos do investimento, pode alterar a orientação ao valor social de cada indivíduo.

A orientação ao valor social é uma medida do quanto um indivíduo se importa com o bem estar dos outros. Um vínculo social é a medida com que o indivíduo se importa com o bem estar de outro indivíduo em específico, enquanto que a orientação ao valor social considera as preferências de distribuição envolvendo um indivíduo arbitrário. Os psicólogos conseguem medir a orientação ao valor social usando técnicas de jogos decompostas como o teste do anel², usado nesse experimento.

O experimento consistiu de uma primeira etapa com um teste do anel para medir a orientação ao valor social. A segunda etapa foi o jogo do investimento em bem público com

² O teste do anel consiste em uma série de escolhas entre duas alocações diferentes de um montante entre o indivíduo avaliado e outra pessoa. Essas escolhas estão dispostas em um círculo onde o eixo x corresponde ao montante do indivíduo avaliado e o eixo y ao montante do outro indivíduo, por isso a referência ao anel. Cada alternativa escolhida pode ser entendida como um vetor. Os vetores resultantes das séries de escolhas são sumarizados e o ângulo resultante pode ser entendido como uma medição da orientação ao valor social do indivíduo. Maiores detalhes na seção 2.1 de van Dijk et al (2002).

25 períodos. E a terceira etapa um novo teste do anel, para verificar o quanto os resultados do jogo alteram essa medição.

Os dados mostram que a orientação ao valor social está correlacionada com a estratégia usada pelos participantes do jogo nas primeiras cinco rodadas, com correlações de Spearman de 0,28 e 0,3, $P < 0,01$, ou seja, indivíduos com maior orientação ao valor social tendem a investir mais em bens públicos. A partir da quinta rodada, a estratégia dos jogadores passa a refletir a própria dinâmica do jogo e menos a orientação ao valor social de cada jogador, ou seja, o jogador passa a basear o quanto investe em bens públicos com base no quanto o outro jogador investiu em bens públicos e esta decisão deixa de estar relacionada à pré-disposição que ele tinha a investir em bens públicos.

O sucesso ou fracasso no jogo de investimento em bem público foi medido pelos ganhos ou perdas que cada jogador teve no jogo. A questão é se a medição do vínculo social³ feita após o jogo estava correlacionada com os resultados obtidos nos jogos. O principal fator que está correlacionado à segunda medição são os resultados obtidos da primeira medição, ou seja, a maior parte do vínculo social medido no final do jogo era devido à orientação ao valor social já existente antes do início do jogo. Contudo o resultado no jogo do investimento também tem correlação com a segunda medição de vínculo social, ou seja, o sucesso ou fracasso no jogo aumenta ou diminui o vínculo social.

³ Como a segunda medição do teste do anel foi feita levando-se em consideração o parceiro no jogo do bem público, os autores usaram a segunda medição para aferir o vínculo social formado com o parceiro do jogo. Assim o primeiro teste mediu a orientação ao valor social e o segundo mediu o vínculo social.

3. RACIONALIDADE LIMITADA E LEARNING CLASSIFIER SYSTEM

Na seção anterior, são relatados vários experimentos que mostram que a decisão dos participantes em jogos do investimento e de bens públicos se afasta das previsões da teoria dos jogos. Uma forma de incorporar essa diferença seria alterar o desenho dos jogos, incluindo alguns elementos que fariam com que a teoria dos jogos previsse a confiança ou altruísmo, mesmo considerando indivíduos racionais. Um exemplo de trabalho que segue essa linha é o de Bester e Güth (1998) que altera as funções de utilidade dos jogadores que passam a incluir os resultados dos outros jogadores. Assim, as funções de melhor resposta são alteradas e a teoria dos jogos passa a prever os resultados obtidos nos experimentos.

Outra forma de incorporar confiança e altruísmo seria o de considerar que os indivíduos não tomam decisões maximizadoras em jogos do investimento e, assim, tentar chegar aos mesmos resultados dos experimentos. Nesse sentido, a teoria da racionalidade limitada e do *satisficing* de Simon (1959, 1979) pode ser útil na definição de outro processo de decisão para substituir a racionalidade maximizadora.

Segundo Simon (1979), a racionalidade limitada é uma característica humana que se refere às nossas limitações cognitivas. Nosso cérebro é mais apto para o reconhecimento de padrões do que para o raciocínio abstrato. Dessa forma, através da racionalidade limitada, conseguimos tomar decisões de forma mais rápida e isso foi crucial para a nossa sobrevivência. Nossas decisões são, portanto baseadas em reconhecimento de padrões e utilização de regras de bolso que transformam problemas de decisões intratáveis em problemas de decisão tratáveis.

Além disso, também não possuímos um comportamento maximizador e sim um comportamento de *satisficing*. Estabelecemos um determinado nível de aspiração e quando o desempenho está abaixo desse nível de aspiração, o comportamento de busca por novas alternativas entra em ação. Ao mesmo tempo, o nível de aspiração tende a se ajustar aos níveis que são atingíveis. Quando esses mecanismos demoram em adaptar as aspirações ao desempenho, o comportamento emocional (apatia, raiva) substitui o comportamento adaptativo (Simon, 1959).

Uma forma de se incorporar os processos de decisão e a racionalidade limitada aos modelos de simulação é o uso do algoritmo de inteligência artificial *Learning Classifier System* (LCS) de Holland (1975, 1996). Esse algoritmo envolve um processo de reconhecimento de padrões do ambiente e o uso de um sistema de classificadores que nada mais são que regras que associam padrões a ações.

Um classificador ou regra de decisão dentro do LCS associa uma condição ambiental a uma ação em particular. A condição ambiental é representada por um vetor com N posições, cada uma referente a uma condição ambiental. Por exemplo, um sistema para escolher onde comer pode envolver três condições: condição financeira (tem ou não dinheiro), disposição (disposto ou com preguiça) e vontade (de comer algo específico). Um classificador para esse sistema associa uma combinação desses fatores com uma ação, por exemplo: a condição seria ter dinheiro, estar com disposição e ter vontade de comer hambúrguer e seria associada à ação ir à lanchonete. Uma regra pode ser específica, como a descrita anteriormente, ou genérica, como por exemplo, se ele não tem dinheiro, não importa as outras duas condições, ele decide comer em casa.

Um sistema de classificadores seria um conjunto de regras que mapeia várias condições ambientais que o agente pode enfrentar associando ações a essas condições. Dessa forma ele pode decidir o que fazer em cada situação. Assim, LCS funciona de forma muito semelhante ao raciocínio indutivo desempenhado pelas pessoas, pois funciona de forma a associar padrões a decisões. Ou seja, esse sistema de classificadores funcionaria como um conjunto de regras de bolso que mapeia as várias situações que o agente pode encontrar e determina quais ações seriam tomadas em cada situação. É desta forma que Simon (1959, 1978 e 1979) descreve o raciocínio humano em seus trabalhos sobre como as pessoas tomam decisões. Portanto, uma modelagem usando o LCS pode trazer resultados diferentes do que prevê a teoria dos jogos que baseia as decisões dos jogadores no raciocínio dedutivo.

Esse sistema de classificadores usa uma forma de aprendizado, o *reinforcement learning*, em que regras que foram utilizadas e que geraram resultados positivos são premiadas com uma maior pontuação e as que geraram resultados negativos são oneradas com uma pontuação menor. Essa pontuação é utilizada para ajudar a escolher qual ação tomar em situações futuras, além de servir como base para a experiência do agente com cada regra. Regras que têm pontuação alta são regras boas e devem ser mantidas para futuras utilizações. Por outro lado, regras que têm pontuação baixa podem ser substituídas por outras que podem se mostrar melhores no futuro.

No início da simulação os agentes recebem um conjunto aleatório de regras e é através do processo de *reinforcement learning* que suas regras de decisão vão se adaptando e gerando resultados melhores. Os agentes podem, portanto receber regras que podem ser julgadas como ingênuas e tomarem decisões pouco inteligentes no começo da simulação. É através do uso e avaliação das recompensas que ele passa a aprender se aquela é uma regra inteligente ou não.

Por exemplo, o sistema de classificadores para decidir onde comer seria inicializado com regras aleatórias como ter dinheiro, estar com disposição, vontade de comer hambúrguer e ter como ação associada ir a um restaurante natural. Ao se deparar com essa situação e decidir, portanto ir a um restaurante natural, o agente teria uma experiência ruim. Consequentemente, a pontuação dessa regra diminuiria e ela seria menos utilizada no futuro em comparação a uma regra como a descrita acima. Esse mecanismo faz com que o agente aprenda que se ele tem vontade de comer hambúrguer, ele deve ir a uma lanchonete ao invés de um restaurante natural.

É importante notar que o julgamento sobre se uma regra ou conjunto de regras é inteligente ou não depende da interação do agente com outros agentes e com o ambiente e não do julgamento de quem elaborou o modelo. Essa dinâmica traz robustez para a simulação e desassocia as propriedades emergentes do modelo com as preferências do modelador.

Outra característica importante do LCS é o algoritmo genético por trás do sistema de classificadores. Eventualmente o sistema testa novas regras, procurando novas formas de interagir com o ambiente. Esse processo leva em consideração a pontuação de cada regra na geração de regras novas. As novas regras serão geradas através de mutação ou cruzamento das regras com maior pontuação. Ou seja, ao explorar novos comportamentos, os agentes usarão como base comportamentos que já se mostraram inteligentes anteriormente. Essas novas regras por sua vez substituirão regras com baixa pontuação e os comportamentos mais prejudiciais ou menos efetivos vão aos poucos sendo abandonados pelos agentes.

O algoritmo genético por trás do LCS pode ser comparado com o processo de *satisficing* de Simon no sentido que os indivíduos cujo desempenho esteja abaixo do nível de aspiração iniciam o processo de busca por novas alternativas. Essas novas alternativas podem eventualmente gerar comportamentos mais bem sucedidos ajudando os indivíduos a atingirem seu nível de aspiração ao mesmo tempo em que abandonam comportamentos ruins.

Os processos de *reinforcement learning* e algoritmo genético do LCS permitem que os agentes aprendam sobre o ambiente em que se encontram e mudem seu comportamento de forma adaptativa à medida que esse ambiente também se altera através da própria interação entre os agentes e o ambiente.

As características da racionalidade limitada e sua similaridade com o algoritmo LCS faz com que este seja uma escolha promissora para modelar o processo de decisão dos agentes num modelo de simulação baseado em agentes.

Wilson et al (2013) usam em seu trabalho o LCS para modelar o aprendizado dos agentes em suas decisões. Desta forma, as decisões que emergem nas simulações podem ser

interpretadas como resultado desse aprendizado. Se essa decisão for pela cooperação entre os agentes, isso significa que esse comportamento trouxe vantagem competitiva a eles em relação a outros agentes que não cooperam e que eles aprenderam isso através da experiência.

O Anexo I contém uma descrição mais detalhada do algoritmo LCS.

4. MODELO DE CONFIANÇA EM UMA SIMULAÇÃO BASEADA EM AGENTES

De acordo com Axelrod (1997), o propósito da modelagem baseada em agentes é entender propriedades de sistemas sociais complexos através da análise de simulações. Esse método de se fazer ciência pode ser contrastado com os dois métodos padrões de indução e dedução. Indução seria a descoberta de padrões em dados empíricos, por exemplo, ao se analisar dados macroeconômicos ou de experimentos, como os descritos acima. Já a dedução envolve especificar uma série de axiomas e provar as consequências que podem ser derivadas dessas premissas. A modelagem baseada em agentes seria uma terceira forma de se fazer ciência. Da mesma forma que a dedução, inicia-se com uma série de premissas, porém, ao invés de se derivar teoremas a partir dessas premissas, geram-se dados simulados através de um conjunto de regras rigorosamente especificadas que são então analisadas indutivamente.

Enquanto que o propósito da indução é identificar padrões e o da dedução é identificar consequências das premissas, o propósito da modelagem baseada em agentes é auxiliar a intuição. Embora as premissas da simulação possam ser simples, suas consequências podem não ser óbvias. Agentes interagindo localmente podem produzir efeitos em larga escala que são chamados de “propriedades emergentes” do sistema. Propriedades emergentes geralmente são surpreendentes, pois pode ser difícil antecipar todas as consequências até mesmo de formas simples de interação.

Assim, ao fazer um modelo baseado em agentes, pode-se entender como a confiança pode emergir através de um conjunto simples de premissas e regras e também entender como pequenas alterações nesse conjunto de premissas e regras afetam ou não a emergência da confiança entre os agentes. Além disso, as simulações permitem analisar regras mais estruturais de formação desses indivíduos, como por exemplo, aprendizado, seleção natural e seleção multinível que são mais difíceis de serem analisadas através de experimentos.

Macy e Skvoretz (1998), Rand et al (2013), Wilson et al (2013) e Manapat, Nowak e Rand (2013) são alguns dos pesquisadores que utilizaram simulações baseadas em agentes para auxiliar o entendimento da confiança e altruísmo entre as pessoas. Nesses trabalhos a confiança ou altruísmo são propriedades emergentes das simulações que utilizam mecanismos variados de aprendizado e evolução nas decisões dos agentes.

Segundo Tesfatsion (2005), a incorporação dos processos de decisão nos modelos tradicionais os torna de difícil análise ou até mesmo impraticáveis. O uso da simulação

baseada em agentes torna essa tarefa mais factível, pois permite incorporar os processos de decisão nos modelos de forma mais simples.

A construção do modelo foi inspirada no trabalho de Epstein e Axtell (1996) onde eles criam uma sociedade artificial através de simulação baseada em agentes e estudam como fenômenos como desigualdade, migração, cultura, guerra, mercado, etc. surgem através de poucas alterações com uma modelagem bem simples do ambiente e dos agentes.

4.1. CONTRUINDO UM MUNDO ARTIFICIAL

O ambiente do modelo é composto de um tabuleiro bidimensional de dimensão 7×7 que é ligado nos extremos numa estrutura toroidal. Nesse ambiente crescem dois tipos de alimentos: frutas e javalis. Cada célula desse tabuleiro tem uma capacidade para que cresçam frutas e para que vivam os javalis, ou seja, algumas células são mais férteis que outras no ambiente. A capacidade de cada célula, tanto para frutas como para javalis, é definida aleatoriamente seguindo uma distribuição uniforme com valores entre 0 e 20^4 . Caso haja coleta de frutas ou caça de javalis numa determinada célula, a quantidade coletada ou caçada é subtraída do estoque que a célula possui. A cada rodada da simulação há uma reposição natural dos estoques de frutas e javalis que crescem até que se atinja a capacidade daquela célula.

Nesse ambiente vivem os agentes da simulação. No início de cada simulação são criados 60 agentes⁵ distribuídos aleatoriamente no ambiente, sendo que uma única célula pode abrigar mais de um agente e não há obrigatoriedade de que toda célula tenha um agente nela. Esses agentes têm duas atividades principais para se alimentarem: eles podem coletar frutas ou caçar javalis. Essas atividades garantem a cada agente as calorias necessárias para a sua sobrevivência. Cada indivíduo também possui um metabolismo que é a quantidade de calorias necessária para a sua sobrevivência a cada rodada. Caso um indivíduo não consiga as calorias necessárias para manter seu metabolismo ou não as tenha no seu estoque de calorias ele morre e é retirado da simulação.

⁴ Sendo 49 posições no tabuleiro, cada uma com uma quantidade aleatória de frutas ou javalis seguindo uma distribuição uniforme entre 0 e 20, a capacidade de frutas ou javalis total do ambiente segue uma distribuição normal com média 490.

⁵ Dada as características do ambiente e das regras de funcionamento do modelo, foi estimado que a capacidade do ambiente é de cerca de 60 agentes. Com menos agentes, a sobrevivência é mais fácil e eles se reproduzem com mais facilidade. Com mais agentes, a sobrevivência é mais difícil e eles morrem com mais facilidade. Definiu-se, portanto, a quantidade de 60 agentes para inicializar o sistema, pois em algumas simulações o processo de reprodução e morte dos agentes foi desligado e essa quantidade permite a comparação entre os modelos diferentes.

Os agentes também possuem um alcance de visão limitado e só conseguem ver a quantidade de frutas e javalis da célula onde se encontram ou das células adjacentes. Porém, eles possuem memória e podem se lembrar de informações de lugares que viram anteriormente.

Cada rodada na simulação corresponde a um dia. E cada dia é dividido em horas. Cada agente possui dez horas por rodada ou por dia para se dedicar às atividades produtivas.

A atividade de coletar frutas é individual. Cada agente depende somente de si para realizar essa tarefa. O agente tem um limite de frutas que pode coletar por rodada, devido ao tempo gasto nessa atividade. Ele coleta a quantidade de frutas correspondente ao maior valor entre sua capacidade de coleta e o estoque de frutas que existe na localidade de coleta. A cada hora o agente consegue coletar uma fruta que possui uma caloria. Todas as frutas são consumidas e suas calorias são apropriadas pelo agente.

Já a atividade de caçar javalis é coletiva e necessita necessariamente de dois agentes para ser realizada. Como os agentes são mais lentos que os javalis eles não podem alcançá-los diretamente. Portanto eles usam uma estratégia em que um agente denominado Direcionador corre atrás de um javali e o direciona até outro agente denominado Matador que então o abate. Porém, o Matador acaba tendo a vantagem de ficar com todo o resultado da caça e precisa então decidir qual parcela da caça ele vai dividir com o Direcionador. Ao término da transação cada agente consome sua parte da caça e suas calorias são apropriadas por cada agente. A cada hora, cada par de agentes consegue caçar um javali que possui três calorias. Da mesma forma que na coleta de frutas, cada par de agentes caça a quantidade de javalis correspondente ao maior valor entre sua capacidade de caça e o estoque de javalis que existe na localidade de caça.

Uma característica importante é que o agente Direcionador pode decidir quanto tempo ele investe na caça de javali e quanto tempo ele investe na coleta de frutas, podendo dedicar a rodada inteira à coleta de frutas, dividir a rodada entre a coleta de frutas e a caça de javali em qualquer proporção ou passar a rodada inteira caçando javalis, respeitando o limite total de dez horas para atividades produtivas. Outra característica importante é que os javalis possuem mais calorias que as frutas, portanto a decisão de caçar javali é ao mesmo tempo mais vantajosa na soma dos dois agentes, mas envolve um risco para o agente Direcionador.

Essas características do ambiente e das atividades de alimentação foram desenhadas para se encaixarem na estrutura do jogo do investimento. Cada agente tem 10 horas diárias para atividades produtivas. O tempo total para atividades produtivas no modelo de simulação seria como a quantidade inicial de dinheiro que o Investidor recebe no jogo do investimento,

ou seja, 10 dólares. A princípio todo o tempo pode ser gasto com a atividade individual de coleta de frutas gerando 10 calorias. Da mesma forma que o Investidor no jogo do investimento pode enviar qualquer valor inteiro entre 0 e 10 dólares, o Direcionador na simulação pode trocar qualquer quantidade entre 0 e 10 horas do tempo da coleta de frutas pela atividade de caçar javalis. Esse tempo gasto na caça de javali rende três vezes mais calorias que na coleta de frutas, o que equivale à taxa de rendimento no jogo do investimento, ou seja, o agente Matador, que seria equivalente ao Parceiro, receberia uma quantidade maior de calorias do que seria obtido na coleta de frutas. Da mesma forma que o Parceiro, o Matador tem que decidir então qual valor de calorias retornará ao outro agente em reciprocidade à sua confiança. O quadro 1 mostra as equivalências entre o jogo do investimento e o modelo de simulação.

Quadro 1 - Equivalência entre jogo do investimento e modelo de simulação

	JOGO DO INVESTIMENTO	MODELO DE SIMULAÇÃO
Dotação inicial (ag. 1)	10 dólares	10 horas de atividades
Agente 1	Investidor	Direcionador
Agente 2	Parceiro	Matador
1ª jogada (agente 1)	Enviar X dólares ao Parceiro Mantém $10 - X$ dólares	Caçar javalis durante X horas Coleta $10 - X$ frutas (calorias)
Remuneração	X é multiplicado por 3	X javalis têm $3X$ calorias
2ª jogada (agente 2)	Mantém Y dólares $\in [0, 3X]$ Retorna $3X - Y$ dólares	Mantém Y calorias $\in [0, 3X]$ Retorna $3X - Y$ calorias
Dotação final (ag. 1)	$10 + 2X - Y$ dólares	$10 + 2X - Y$ calorias

Fonte: Elaboração própria

4.2. SELEÇÃO

Por se tratar de um modelo evolucionário, precisamos de um mecanismo para que agentes mais bem adaptados ao ambiente se sobressaíam em relação aos agentes menos adaptados. Um mecanismo é o próprio metabolismo do agente que faz com que ele morra e seja retirado do ambiente caso não consiga as calorias necessárias para sua sobrevivência. Outro mecanismo seria a reprodução que replicaria com maior probabilidade as características que sejam mais adaptadas ao ambiente.

Um agente para se reproduzir precisa ter uma quantidade mínima de calorias em estoque, pois parte dessas calorias será doada para seu descendente no momento do nascimento. Caso ele se reproduza com uma quantidade baixa de calorias, ele fica mais exposto a eventuais choques de escassez de alimentos no ambiente. Esse número de calorias passado ao seu descendente é equivalente à metade do seu estoque e limitado a uma quantidade definida globalmente.

Ao se reproduzir o agente também passa para seu descendente uma cópia das suas regras de decisão atuais. Porém, após o nascimento, as regras do descendente passam a evoluir de forma independente de acordo com sua própria experiência e não mantém mais nenhuma relação com as regras do seu antecedente.

À medida que os agentes vão desenvolvendo regras boas, eles conseguem capturar mais recursos do ambiente aumentando seus estoques de calorias, o que possibilita que eles se reproduzam com mais segurança e também com maior probabilidade. Porém, à medida que a população de agentes aumenta, os recursos vão ficando cada vez mais escassos e isso torna a sobrevivência dos menos adaptados mais difícil, regulando assim a quantidade de agentes total.

4.3. REGRAS DE DECISÃO

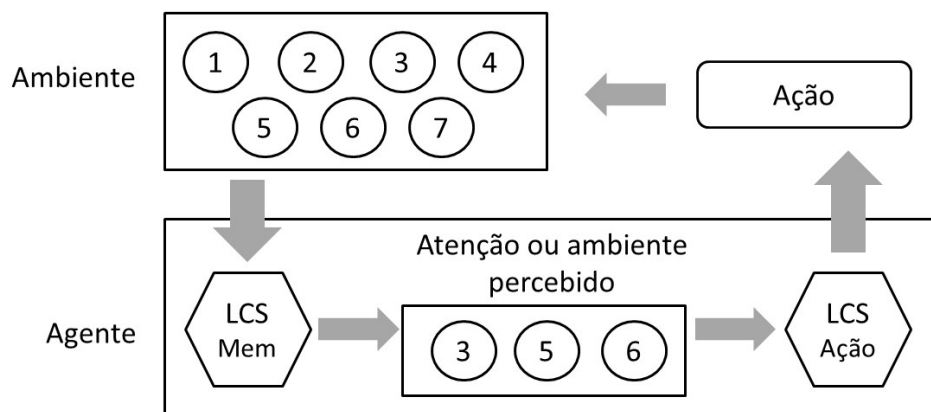
Dentro desse mundo artificial, os agentes têm que aprender sobre o ambiente e decidir como agir de forma a garantir sua sobrevivência. Conforme visto anteriormente, o modelo usa um algoritmo de inteligência artificial que replica mais fielmente a racionalidade limitada e, portanto opta-se pelo uso do LCS para modelar os processos de decisão dos agentes.

Nessa simulação os agentes têm que decidir se vão coletar frutas ou caçar javalis, porém essa decisão tem que ser quebrada em algumas decisões menores. Por exemplo, ao decidir coletar frutas, o agente tem que decidir também onde coletar frutas e essa decisão tem que ser baseada na forma como ele percebe o ambiente. E a forma como ele percebe o ambiente depende também da atenção que ele dá a cada informação que obtém do ambiente.

Esse processo segue a lógica da racionalidade procedural de Simon (1978). Em decisões complexas existe uma diferença considerável entre o ambiente real em que uma decisão ocorre e o ambiente da forma como os agentes o percebem. Em um ambiente onde a quantidade de considerações relevantes para uma decisão é muito grande, apenas a parte mais relevante acaba tendo a devida atenção. Nesse contexto, a racionalidade se expressa como reação às consequências desse ambiente percebido.

Assim, a construção da racionalidade dos agentes pode ser feita em etapas: uma voltada para a atenção, que é escassa devido às limitações da mente humana, e outra que é voltada para a decisão em si, que é condicionada ao ambiente percebido e não a todo fator relevante na análise. Por exemplo, na figura 2 temos um ambiente formado por sete informações que são importantes para a tomada de decisão. Porém, ao analisar essas informações, o agente enfrenta uma limitação cognitiva que restringe sua capacidade de levar em consideração o todo. Portanto, sua atenção se volta a apenas três informações que ele julga serem as mais importantes. É em cima dessas três informações que ele toma a decisão. A ação que o agente decidiu tomar, por sua vez, afeta todo o ambiente e pode ter reflexo inclusive nos itens que ele não levou em consideração na sua análise.

Figura 2 - Processo de decisão de um agente usando LCS



Nota: O primeiro processo seria a atenção dada ao ambiente e quais fatores desse ambiente pra ele são mais relevantes para seu processo de decisão. Uma vez que ele percebeu o ambiente ele usa um processo de decisão com base nas informações que ele percebeu como relevantes. Essa ação por sua vez tem impacto no ambiente alterando-o e o ciclo se reinicia.

Fonte: Elaboração própria.

Vale notar que o processo de atenção é modelado também com o algoritmo LCS. Sendo assim, o agente vai aprendendo pela sua experiência que informações do ambiente são importantes para se levar em consideração para a tomada de decisão.

Esse é o processo usado no modelo de simulação para modelar a decisão dos agentes. Por exemplo, na atividade de coleta de frutas um agente consegue olhar para vários lugares ao redor dele, cada um com uma determinada quantidade de frutas. Para que ele decida onde ele vai coletar, ele deve primeiro decidir em quais desses lugares ele vai prestar atenção para então decidir onde deve coletar frutas. Analogamente ao fluxo da figura 2 ele filtra apenas alguns lugares, de todos os que ele tem disponíveis para coletar frutas, para sua análise. Além disso, ele também deve decidir se mantém ou não em sua memória posições que ele não vê

mais. Por exemplo, numa rodada anterior ele memorizou que um lugar A possuía uma quantidade de frutas N. Nesta rodada ele não consegue mais visualizar esse local A e deve decidir então se ele descarta essa informação, ou a mantém para as próximas decisões. Como a memória é limitada, guardar informações de lugares que ele não vê mais significa levar em consideração menos posições que ele consegue ver em sua tomada de decisão.

4.4. FORMAÇÃO DE GRUPOS E SELEÇÃO MULTINÍVEL

Ao se modelar a confiança e a reciprocidade dos agentes na simulação, é preciso ter em mente o conceito de seleção multinível. Wilson e Wilson (2007) mostram como esse conceito está ressurgindo na sociobiologia baseado em evidências empíricas e novas teorias. De acordo com esse conceito, o altruísmo desfavorece a seleção intragrupos, porém favorece a seleção entregrupos. Ou seja, ele pode tornar a sobrevivência mais difícil no nível individual em relação a outros membros do grupo, mas se uma proporção considerável de indivíduos dentro deste grupo apresentar características de altruísmo, esse grupo pode ser mais adaptável à sobrevivência do que outro grupo que não apresente características de altruísmo.

Alguns exemplos dessa dinâmica são: organismos multicelulares que se tornaram mais adaptados do que organismos unicelulares através da especialização das células em funções específicas e sua consequente dependência das demais células para sobrevivência; formação de colônias em determinadas espécies de insetos, onde cada indivíduo também se especializa e torna sua sobrevivência dependente dos demais; e também como humanos evoluíram para favorecer comportamentos grupais e normas sociais.

Sendo assim, o surgimento da confiança e da reciprocidade está condicionado à construção de grupos dentro do sistema. No início da simulação, cada agente é associado aleatoriamente a uma posição do tabuleiro que passa a ser seu local de residência. Esses agentes podem realizar atividades de coleta e caça tanto dentro da célula em que residem quanto em qualquer outra célula do ambiente, mas devem retornar ao seu local de residência para descansarem. No modelo de simulação, um grupo é definido como os agentes que residem na mesma localidade. Dessa forma, com a formação de grupos, os agentes devem ser pareados somente entre os agentes do seu grupo. Eventualmente (0,1% de chance a cada rodada) um agente pode migrar para uma posição aleatória no tabuleiro possibilitando ingressar em um novo grupo ou até mesmo formar um novo grupo.

Alguns trabalhos que modelaram a confiança em modelos computacionais ou simulações baseada em agentes (Manapat et al, 2013 e Macy e Skvoretz, 1998) mostram que

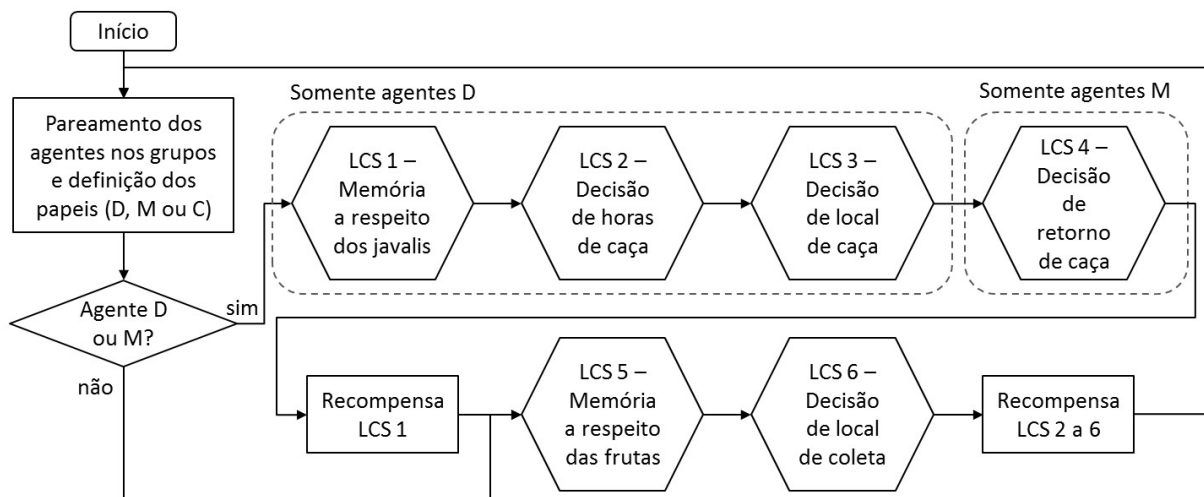
ao se considerar toda a população como um único grupo, podem existir efeitos de contágio, onde um agente mutante não cooperativo que surge dentro de uma população cooperativa pode adquirir vantagens em relação ao seus pares e gradativamente se tornar dominante. Isso faz com que existam ciclos de confiança alternados com ciclos de egoísmo na população como um todo. Porém, os dados obtidos em vários experimentos com jogos de confiança (Camerer, 2003) têm apresentado a existência de cooperação para várias localidades ao longo do tempo.

Com a seleção multinível, mesmo que dentro de um grupo haja dominância de um mutante não cooperativo fazendo com que todo o grupo se torne individualista, a existência de outros grupos cooperativos pode desfavorecer esse grupo não cooperativo em sua sobrevivência como grupo.

4.5. DECISÕES DOS AGENTES NA SIMULAÇÃO

Além da forma como os agentes tomam as decisões na simulação, é necessário especificar também quais decisões os agentes tomam e qual a dinâmica desse processo de decisão. A figura 3 mostra um esquema de quais são os processos de decisão e em que ordem eles acontecem na simulação.

Figura 3 - Fluxo dos processos de decisão dos agentes do modelo



Fonte: Elaboração própria

No início de cada rodada, os agentes que fazem parte de um mesmo grupo são pareados aleatoriamente e recebem também de forma aleatória o papel de Direcionador (D) ou

Matador (M), sendo que cada par é formado necessariamente por um D e um M. Caso em um grupo haja somente um agente, ou seja, naquela localidade somente reside uma única pessoa, ela recebe necessariamente o papel de Coletor (C). Se em um grupo houver um número ímpar de agentes, o agente que não for pareado também receberá necessariamente o papel de Coletor (C). Os papéis recebidos pelos agentes a cada rodada definem suas decisões naquela rodada. Vale lembrar que o processo de pareamento ocorre no início de toda rodada e a cada rodada os papéis podem ser diferentes. Em cada rodada, em torno de 15 a 25 agentes recebem o papel de D e a mesma quantidade o papel de M, dado que pra cada D existe necessariamente um M. Essa quantidade vai depender da forma que os agentes estão distribuídos no ambiente. Em seguida, todos os agentes D devem decidir quantas das 10 horas que ele possui na rodada ele vai dedicar à caça com seu parceiro M. Porém antes disso, ele vai realizar o processo de olhar as informações disponíveis a respeito das condições de caça, ou seja, a quantidade de javalis existentes e memorizar as informações que ele julga interessante. Esse processo é basicamente olhar a quantidade de javalis das posições adjacentes a ele e decidir uma a uma se ela deve ou não substituir uma informação que ele possui na sua memória.

Realizado o processo de atualização da memória, a questão passa a ser quantas horas ele vai passar caçando, sendo que o restante das horas não usadas para caçar serão necessariamente dedicadas à coleta de frutas. Para essa decisão ele leva em consideração a relação entre a maior quantidade de javalis e de frutas que ele memorizou, o valor dessa quantidade de javalis e o histórico dos retornos das últimas caçadas em que ele foi o agente D. Vale lembrar que no início da simulação as regras são definidas aleatoriamente e é através do processo de aprendizado pelo reforço que elas vão se adaptando ao ambiente.

Após a decisão de quantas horas ele vai caçar, a segunda decisão dos agentes D passa a ser a localidade em que ele vai realizar a caça. Para essa decisão ele leva em consideração as informações que ele tem em sua memória. Com as informações de quantidade de horas e local de caça, a caça é feita e os resultados são apurados. O resultado da caça é o mínimo entre a quantidade de javalis existente no local de caça e as horas de caça. Por exemplo, se o agente D decidiu caçar por cinco horas, porém só havia três javalis no local, o resultado da caça é de três javalis. Por outro lado se lá havia sete javalis, o resultado da caça é de cinco javalis.

Com o resultado da caça na mão, o processo de decisão passa para o agente M que tem que decidir agora qual percentual das calorias obtidas na caça deve retornar ao agente D. Para essa decisão ele leva em consideração a relação entre a maior quantidade de javalis e de frutas que ele memorizou, a quantidade total de horas de caça da rodada e o histórico de horas de caça nos quais ele foi o agente D.

Como o LCS usa o aprendizado para melhorar o processo de decisão, é necessário avaliar as recompensas de cada uma das decisões que foram tomadas na rodada. Para isso, é necessário estabelecer qual o critério que será utilizado para avaliar a recompensa de cada decisão, pois esse é o direcionamento que será dado para sua evolução. Por exemplo, para avaliar uma regra no processo de atenção ou memória de um agente a respeito da quantidade de javalis, é necessário que se avalie o objetivo dessa decisão que seria o de garantir uma boa caça, ou seja, que o agente esteja caçando nas melhores posições possíveis. Assim, uma métrica para saber se ele está tomando a decisão correta seria o resultado da caça daquela rodada. Decisões que gerem grandes caças terão sua pontuação aumentada o que as promovem como favoritas em decisões futuras. Analogamente, decisões que gerem pouca ou nenhuma caça terão sua pontuação diminuída e a chance de elas serem usadas novamente cai. O quadro 2 mostra as informações usadas em cada processo de decisão e como o valor de recompensa de cada regra é avaliado.

Quadro 2 - Informações usadas no processo de decisão e forma de avaliação da recompensa

LCS	Informações usadas	Avaliação da regra (<i>fitness</i>)
1 – Memória a respeito dos javalis	Quantidade de javalis nas células adjacentes	Resultado da caça
2 – Decisão de horas de caça	Qtde javalis / qtde frutas na memória; qtde javalis na memória e histórico dos retornos das últimas caçadas	Resultado total da rodada – calorias obtidas tanto de javalis como de frutas
3 – Decisão de local de caça	Informações da memória a respeito dos javalis	Resultado da caça
4 – Decisão de retorno de caça	Qtde javalis / qtde frutas na memória; horas de caça da rodada e histórico de horas de caça	Histórico de resultado total – calorias obtidas tanto de javalis como de frutas
5 – Memória a respeito das frutas	Quantidade de frutas nas células adjacentes	Resultado da coleta
6 – Decisão de local de coleta	Informações da memória a respeito das frutas	Resultado da coleta

Fonte: Elaboração própria

Nessa etapa da rodada, os agentes D já têm o resultado da caça e assim podem avaliar se as regras que eles utilizaram para a atenção ou memória a respeito da quantidade de javalis foram boas ou não. Essa avaliação é feita e essas regras passam a ter novos valores de recompensa (*fitness*).

Já para as regras de decisão de horas de caça do agente D, é necessário avaliar o resultado total da rodada, incluindo também a quantidade de frutas coletadas. Por isso, a avaliação dessas regras não é feita nesse momento.

Com relação à avaliação das regras de retorno dos resultados da caça do agente M, é necessário um cuidado adicional. Caso um agente olhe somente o resultado da transação daquela rodada ele vai direcionar a evolução da regra para resultados de curto prazo e assim a consequência provável seria um comportamento mais egoísta resultando em regras que não retornem nada ao agente D. Portanto é necessária outra forma de avaliação de resultados.

Sendo assim, foi utilizado como base o conceito de reciprocidade indireta, onde uma pessoa pode escolher ser gentil com outra, mesmo na impossibilidade de reciprocidade direta, na esperança de que essa pessoa seja gentil nas próximas interações e isso acabe gerando um ambiente social agradável que trará reflexos positivos pra ela própria no futuro. Desta forma, ao se avaliar os resultados das regras de retorno dos resultados da caça do agente M, é necessário avaliar o resultado total de longo prazo, incluindo as caças e coletas de frutas. No modelo de simulação utiliza-se o resultado médio das últimas seis rodadas em que ele foi o agente M.

Terminado o processo de caça, os agentes do modelo passam a tomar as decisões relativas à coleta de frutas. Analogamente ao processo de caça, a primeira etapa do processo de coleta é exatamente o processo de memória ou atenção, porém relativo à quantidade de frutas do ambiente.

Em seguida ele passa a decidir onde ele vai fazer a coleta de frutas baseado nas informações que ele tem em sua memória. Ele então coleta as frutas na localidade escolhida durante as horas restantes, ou seja, que não foram utilizadas em atividades de caça como agente M ou D. O processo é similar ao da caça, a quantidade de frutas coletadas é o mínimo entre as horas de coleta e a quantidade de frutas do local.

Com os resultados da coleta apurados, pode-se fazer a avaliação das regras utilizadas tanto no processo de decisão de coleta de frutas como nas regras de decisão de caça que dependem também das informações de coleta de fruta. Esses resultados são apurados nesse momento. A rodada termina e inicia-se uma nova rodada.

5. MODELO GENERATIVO, AVALIAÇÃO DE FATORES E RESULTADOS

Conforme mencionado anteriormente, a construção desse modelo de simulação baseada em agentes foi inspirada no trabalho de Epstein e Axtell (1996). A estratégia utilizada por eles foi montar um modelo de simulação com regras simples de busca por alimento e sobrevivência e, com base nesse modelo mais simples, introduzir alguns fatores e avaliar as propriedades emergentes ocasionadas por eles. Por exemplo, quando eles introduziram a reprodução sexual no modelo, foi possível observar a emergência de flutuações na densidade populacional. Como a reprodução é local, uma população pode se tornar extinta se as pessoas se distribuem de forma esparsa. Isso mostrou que a extinção pode ser um fenômeno endógeno. Quando introduziram cultura e conflito no modelo, foi possível observar a emergência de formação de tribos e até mesmo guerras entre tribos por disputa de recursos.

De acordo com os autores, a modelagem de sociedades artificiais nos permite “cultivar” estruturas sociais que mostram que certas microespecificações são suficientes para gerar macrofenômenos de interesse. Dessa forma, através da modelagem de uma sociedade artificial, é possível definir uma estratégia para analisar como alguns fatores podem ser suficientes para a emergência da confiança entre agentes. Essa estratégia consiste em elaborar um modelo simples que será denominado Modelo Base e introduzir os fatores a serem analisados um a um, avaliando a emergência do fenômeno de interesse, nesse caso, a confiança entre agentes.

No início da simulação cada agente recebe aleatoriamente um conjunto de regras de decisão que vai se adaptando e evoluindo conforme a experiência que cada agente tem no ambiente da simulação. Ou seja, no começo da simulação as decisões dos agentes são aleatórias e elas podem tanto favorecer como também desfavorecer sua sobrevivência. De forma geral, essas regras podem evoluir através de dois mecanismos distintos: aprendizado e seleção.

Pelo mecanismo de aprendizado cada agente avalia as recompensas das decisões que tomou e premia as mais bem sucedidas ao mesmo tempo em que demove as que não se mostraram boas. Decisões com alta pontuação são escolhidas mais frequentemente e também são usadas como modelo para testar regras de decisões novas. Analogamente, decisões com baixa pontuação são pouco escolhidas e também são mais facilmente substituídas por regras de decisões novas. Sendo assim, podemos elaborar um modelo de simulação onde esse mecanismo de avaliação de decisões não ocorre e a experiência que cada agente têm ao interagir com o ambiente não tenha relevância nas decisões futuras. Esse modelo seria um

modelo sem aprendizado. A comparação entre as decisões dos agentes em modelos com e sem aprendizado pode indicar que efeito o aprendizado tem na emergência da confiança.

Com relação ao mecanismo de seleção, vimos que os agentes possuem um estoque de calorias e um metabolismo. Se a atividade produtiva traz mais calorias que o metabolismo de cada agente, o estoque de calorias aumenta. Caso contrário, o estoque diminui e se ele zera, o agente morre e é retirado da simulação. Isso faz com que a participação de agentes com decisões ruins diminua ao longo do tempo. Por outro lado, caso o estoque de calorias aumente, aumenta também a probabilidade do agente se reproduzir e com isso passar as suas regras de decisão para seus descendentes. Portanto, decisões boas podem fazer com que um agente se reproduza mais e que mais agentes contem com as mesmas decisões. Um modelo de simulação sem seleção seria um modelo em que a morte e reprodução de agentes não ocorrem. Da mesma forma que com relação ao aprendizado, podemos comparar as decisões dos agentes em modelos com e sem seleção e verificar que efeito ela tem na emergência da confiança.


Outro fator de interesse no modelo é a formação de grupos que permite que a seleção multinível tenha efeito. Conforme descrito na seção anterior, os grupos são definidos pelos agentes que residem na mesma localidade e os agentes são pareados somente dentro do seu próprio grupo. Pela seleção multinível, agentes altruístas têm desvantagens competitivas dentro do seu grupo, caso o grupo seja formado majoritariamente por agentes egoístas, porém grupos majoritariamente altruístas têm vantagens competitivas em relação a grupos majoritariamente egoístas. Um modelo sem a formação de grupos⁶ seria um modelo em que os agentes são pareados entre todos os agentes da simulação. Podemos então verificar o efeito que a formação de grupos tem na emergência da confiança entre os agentes.

Para analisar o efeito de cada fator na emergência da confiança no modelo de simulação, foram rodadas 50 simulações para cada tipo de modelo: 1) Base, 2) Aprendizado, 3) Seleção, 4) Aprendizado e Seleção, 5) Aprendizado e Grupos, 6) Seleção e Grupos e 7) Aprendizado, Seleção e Grupos. Cada simulação foi acompanhada durante 2000 rodadas. A análise da cooperação entre os agentes se dará através das duas decisões de escolha da atividade produtiva: confiança, ou quantas horas o agente Diretor (D) decide dedicar à

⁶ Como os agentes no modelo com formação de grupos só são pareados dentro dos seus grupos, a quantidade de grupos com quantidade ímpar de agentes é igual ao número de agentes que serão somente coletores naquela rodada. Isso pode distorcer a comparação entre modelos se parearmos todos os agentes no modelo sem formação de grupos. Para preservar a comparabilidade, no modelo sem formação de grupos, os agentes que são somente coletores são definidos prioritariamente de forma aleatória com base no número de grupos com número ímpar de agentes e somente depois os demais agentes são pareados.

caça, e reciprocidade, o percentual de calorias obtidas pela caça que o agente Matador (M) decide dividir com o agente D. Para cada simulação foi calculada a média⁷ de horas de caça decididas pelos agentes D e percentual de divisão da caça decididos pelos agentes M. Os resultados das simulações podem ser observados nos gráficos 1 e 2. As próximas subseções trazem a análise dos resultados obtidos.


Gráfico 1 – Horas de caça decididas pelos agentes D



Fonte: Modelo de simulação. Elaboração própria.

⁷ Para aumentar a quantidade de observações, os valores médios de horas de caça foram calculados a cada 20 rodadas. Portanto o valor médio de horas de caça da rodada 2000 corresponde ao valor médio de horas de caça das rodadas 1981 a 2000

Gráfico 2 – Percentuais de divisão da caça decididos pelos agentes M



Fonte: Modelo de simulação. Elaboração própria.

5.1. MODELO BASE

Conforme visto anteriormente, no início da simulação os agentes são inicializados com regras de decisão aleatórias e agem de forma completamente ingênua frente a situações com as quais ele se depara. Caso não haja nenhuma pressão pela adaptação, como aprendizado, seleção ou formação de grupos, esse comportamento aleatório tende a se perpetuar sem que os agentes mudem seu comportamento. O modelo com essas características será denominado Modelo Base e servirá de referencial para comparação com os outros modelos onde os fatores de adaptação do comportamento serão introduzidos para verificar seus efeitos.

Com relação à confiança no Modelo Base, o agente D pode decidir dedicar à caça um valor entre 0 e 10 horas. Como os agentes têm decisões aleatórias, elas são uniformemente distribuídas entre 0 e 10 horas⁸. A média das decisões dos agentes D a cada rodada da simulação deveria seguir uma distribuição normal com média 5.

Logo nas primeiras rodadas verifica-se que foram dedicadas em média 4,95 horas de caça considerando as 50 simulações do Modelo Base. O desvio padrão das horas dedicadas à

⁸ Por questão de simplificação do modelo, as decisões de horas de caça foram restritas às opções: 0, 2, 5, 8 e 10 horas. A média das decisões não se altera, somente o desvio padrão que muda de 3,16 para 3,69.

caça nas 50 simulações foi de 0,48. O intervalo de 95% de confiança para a média das horas de caça é [4,81; 5,09]. Ao longo das simulações a média se mantém próxima de 5 horas de caça e o intervalo de 95% de confiança abrange o valor correspondente ao comportamento aleatório, conforme se verifica no gráfico 1. Pode-se confirmar, portanto, que o comportamento de confiança dos agentes no Modelo Base é aleatório e se mantém aleatório ao longo das simulações.

Com relação à reciprocidade, o raciocínio é idêntico ao da confiança. O agente M pode decidir dividir com o agente D qualquer percentual entre 0% e 100% do resultado da caça. Como os agentes têm decisões aleatórias, suas decisões estão uniformemente distribuídas entre 0% e 100%⁹. A média das decisões dos agentes M deveria seguir uma distribuição normal com média 50%.

Nas primeiras rodadas pode-se notar que em média os agentes M destinaram 50,0% do resultado da caça aos Direcionadores considerando as 50 simulações. O desvio padrão do percentual dividido foi de 4,1%. O intervalo de 95% de confiança para a média dos percentuais de retorno é [48,8%; 51,1%]. Ao longo das simulações a média se mantém em torno de 50% e o intervalo de 95% de confiança abrange o valor correspondente ao comportamento aleatório, conforme o gráfico 2. Pode-se confirmar, portanto, que o comportamento de reciprocidade dos agentes M no Modelo Base é aleatório e se mantém assim ao longo das simulações.

É importante notar a diferença entre o comportamento aleatório e a previsão do equilíbrio de Nash com agentes racionais e egoístas. O comportamento aleatório leva a uma média de 5 horas de caça e 50% de divisão do resultado da caça. No entanto, a previsão do equilíbrio de Nash seria de zero hora de caça e 0% de divisão. Sendo assim, para verificar a emergência de cooperação é importante testar os valores obtidos nas simulações para diferenças tanto com relação ao comportamento aleatório como também para o comportamento racional como representado na teoria dos jogos tradicional. Nas comparações que serão descritas a seguir, utilizou-se como critério que um deslocamento do comportamento aleatório para valores maiores, ou seja, no sentido oposto do comportamento racional e egoísta indica aumento de cooperação. Por exemplo, um agente D que passou caçando uma quantidade de horas significativamente maior que 5 é um agente que passou a ter

⁹ Neste caso, também por questões de simplificação, as decisões de reciprocidades ficaram restritas às opções: 0%, 25%, 50%, 75% e 100%. A média não se altera e o desvio padrão passa de 0,29 quando se considera uma distribuição uniforme contínua para 0,35.

comportamento cooperativo. Por outro lado, um agente D que passou de forma significativa menos que 5 horas caçando é um agente que passou a ter comportamento egoísta.

5.2. APRENDIZADO

Partindo do Modelo Base e permitindo que os agentes passem agora a mudar suas regras de decisão conforme a experiência que eles têm ao interagir com o ambiente e outros agentes, pode-se notar que há deslocamento da média das decisões dos agentes tanto com relação à confiança quanto com relação à reciprocidade.

Logo no início das simulações, percebe-se que os agentes D decidem caçar durante 5,03 horas em média, com desvio padrão de 0,49. O intervalo de 95% de confiança é [4,88; 5,12] e, portanto, podemos aceitar que as decisões dos agentes D são aleatórias.

Porém, na rodada 80 já se verifica que os Direcionadores passam em média 5,21 horas caçando, com desvio padrão de 0,43. O intervalo de 95% de confiança é [5,09; 5,33] e podemos aceitar que a média é diferente de 5 horas e não são mais aleatórios. Além disso, verifica-se que o deslocamento foi para cima, ou seja, as decisões não só se afastaram do comportamento aleatório como elas se alteraram em direção oposta ao comportamento racional da previsão do equilíbrio de Nash indicando que o aprendizado favorece o comportamento cooperativo. A média de horas dedicadas à caça continua a aumentar conforme se verifica no gráfico 1 e chega a 5,82 horas, com desvio padrão de 0,36 na rodada 2000.

Com relação à decisão dos agentes M, verifica-se também, que no início das simulações eles dividem com os agentes D 49,7% do resultado da caça com desvio padrão de 4,4%. O intervalo de 95% de confiança é [48,4%; 50,9%] e, portanto, podemos aceitar que as decisões dos agentes M são aleatórias.

Na rodada 80 se verifica que os agentes M dividem 48,4% do resultado da caça com os agentes D com desvio padrão de 4,9%. O intervalo de 95% de confiança é [47,0%; 49,8%] e podemos aceitar que a média é diferente de 50%. Diferentemente da decisão dos agentes D, verifica-se aqui que o deslocamento foi para baixo, em direção ao que se espera de um agente racional. A média do percentual da caça dividido com os agentes D continua a cair ao longo da simulação chegando a 40,2% com desvio padrão de 3,8% na rodada 2000 conforme o gráfico 2.

Ao se inserir o aprendizado no Modelo Base verifica-se um deslocamento no comportamento dos agentes, sendo que os agentes D passam a ter um comportamento mais

cooperativo e os agentes M passam a ser mais egoístas. Lembrando que o papel dos agentes é definido de forma aleatória e os agentes podem alterar o papel entre Direcionadores e Matadores em diferentes rodadas.

De forma geral, mesmo os agentes M sendo mais egoístas que no Modelo Base, dado que cada hora de caça rende três calorias, os agentes D ainda obtêm lucro caso os percentuais de divisão estejam acima de 33,3% e esses movimentos não parecem ser estranhos. O mais importante aqui é que só o aprendizado através do algoritmo LCS já é capaz de fazer com que haja emergência de cooperação entre os agentes.

5.3. SELEÇÃO

Partindo também do Modelo Base e pressionando os agentes para que consigam calorias necessárias para atender seu metabolismo e assim garantir sua sobrevivência e, além disso, permitindo também que aqueles com mais sucesso no acúmulo de estoque de calorias possam se reproduzir e passar suas regras de decisão a seus descendentes, verifica-se também que há um deslocamento da média das decisões tanto dos agentes D como dos agentes M.

No início das simulações, pode-se aceitar que os agentes são inicializados com comportamento aleatório, tanto os agentes D que apresentam 5,05 horas de caça em média, com desvio padrão de 0,42 e intervalo de 95% de confiança de [4,93; 5,17], como também os agentes M que apresentam em média 49,4% de divisão dos resultados das caças com os agentes D, com desvio padrão de 3,6% e intervalo de 95% de confiança de [48,4%; 50,4%].

Analisando primeiramente o comportamento dos agentes M, verifica-se que logo no início da simulação seu comportamento passa a ser levemente mais egoísta, atingindo na rodada 90 média de 47,5% de destinação dos resultados aos Direcionadores ($DP = 3,9\%$ e $IC = [46,4\%; 48,6\%]$), e sendo possível aceitar que esse resultado não é mais aleatório.

Mais ou menos a partir dessa rodada, os agentes menos aptos, que foram inicializados com regras menos eficientes, começam a esgotar seu estoque inicial de calorias e passam a morrer. Isso faz com que o comportamento médio dos agentes M apresente uma tendência mais forte de se tornar cada vez mais egoísta. Na rodada 500, foi destinado aos agentes D 13,3% do resultado da caça em média ($DP = 5,6\%$) e na rodada 1000 esse valor já passa a ser de 4,4% ($DP = 4,7\%$), chegando a 2,4% ($DP = 6,4\%$) na rodada 2000. Esses valores estão bem próximos do comportamento racional previsto pelo equilíbrio de Nash.

Analisando agora o comportamento dos agentes D, verifica-se que logo no início da simulação o comportamento deles se desloca levemente em direção a uma cooperação maior,

atingindo 5,13 horas de caça em média ($DP = 0,41$ e $IC = [5,01; 5,25]$), sendo possível aceitar que neste momento o resultado não é mais aleatório.

Porém, a pressão pela sobrevivência que se inicia nesse momento não têm o efeito de tornar a decisão dos agentes D mais egoísta, como no caso dos agentes M. Na rodada 500, a média de horas de caça foi de 6,03 ($DP = 0,75$), indicando maior cooperação. Porém, a partir deste momento, a confiança começa a cair, atingindo 5,38 horas de caça ($DP = 1,10$) na rodada 1000 e caindo mais ainda até a rodada 2000, quando chega a 4,31 horas ($DP = 2,01$).

É importante notar que o desvio padrão das horas de caça aumenta com o passar do tempo. Algumas simulações chegam a atingir valores bem altos de confiança, com até oito horas de caça em média na rodada 2000, mesmo com valores quase nulos de percentuais de divisão da caça. O teste de Pearson mostra que não há evidência de correlação entre os valores de horas de caça e de percentuais de divisão de caça na rodada 2000 ($p = 0,8494$). Sendo assim, é provável que o que ocasiona a queda da média dos valores de caça seja a pressão exercida pela seleção e não a queda dos valores de reciprocidade.

Comparando os resultados do modelo com seleção com os do modelo com aprendizado, observa-se que há uma tendência de os agentes M se comportarem de forma mais egoísta e que a seleção coloca uma pressão maior para que esses agentes se comportem assim. Já os agentes D tem uma propensão a serem mais cooperativos no início dos dois modelos. Porém, a seleção acaba pressionando também o comportamento dos agentes D para se tornarem mais egoístas, o que não ocorre no modelo com somente aprendizado.

Outro modelo a ser analisado é o que apresenta tanto o aprendizado como também a seleção. Nesse modelo podemos observar que os agentes M apresentam o mesmo comportamento que no modelo somente com seleção, ou seja, o comportamento inicia aleatório se tornando levemente egoísta nas primeiras rodadas e adquirindo um comportamento mais fortemente egoísta a partir daí até o final da simulação.

O teste de diferença entre o comportamento dos agentes M no modelo com aprendizado e seleção e no modelo com somente seleção diz que não se pode afirmar que esses comportamentos sejam diferentes (Welch test $p\text{-value} = 0,06451$).

Com relação ao comportamento dos agentes D no modelo com aprendizado e seleção, a dinâmica também é parecida com o comportamento no modelo somente com seleção. Eles começam a se comportar de forma aleatória, passando a adquirir um comportamento mais cooperativo logo no início das simulações e por volta da rodada 500 começam a sentir a pressão por um comportamento mais egoísta, diminuindo a cooperação. Além disso, os desvios padrões das horas de caça são menores que no modelo somente com seleção.

Porém, a redução da cooperação é menor que no modelo somente com seleção. No caso do comportamento dos agentes Direcionadores, o teste de diferença mostra que se pode afirmar que os comportamentos são diferentes (Welch test p-value = 0,00772). Além disso, ao se testar a correlação entre horas de caça e percentuais de divisão da caça, pode-se aceitar que existe correlação entre eles (Pearson p-value = 0,03454). Sendo assim, o aprendizado pode reduzir a pressão exercida pela seleção por um comportamento mais egoísta dos agentes D, além de permitir que eles interpretem melhor um ambiente mais egoísta e se adaptem melhor a ele.

5.4. FORMAÇÃO DE GRUPOS

Conforme visto anteriormente, podemos definir um grupo como os agentes que residem na mesma localidade. Neste caso, os grupos podem desenvolver comportamentos distintos e a formação dos grupos pode ter efeito no sucesso de cada grupo. O altruísmo prejudica a seleção intragrupo, porém, favorece a seleção entregupo.

Partindo do modelo somente com aprendizado e introduzindo a formação de grupos, não há mudança significativa no comportamento tanto dos agentes D como dos agentes M, conforme se pode observar nos gráficos 1 e 2.

O teste de diferença entre o comportamento dos agentes D mostra que não há indicativo de que esses comportamentos sejam diferentes nos dois modelos (Welch test p-value = 0,1436).

O teste de diferença também mostra que não há indicativo de que o comportamento dos agentes M seja diferente nos dois modelos (Welch test p-value = 0,2967). Portanto a formação de grupos não parece exercer influência em modelos que não tenham seleção.

Partindo agora do modelo somente com seleção e introduzindo a formação de grupos, verifica-se que a seleção passa a exercer menos pressão nos agentes M nas decisões de divisão da caça e, embora eles ainda apresentem comportamento fortemente egoísta, eles são menos egoístas que no modelo sem formação de grupos.

O teste de diferença mostra que podemos afirmar que o comportamento dos agentes M é diferente nos dois modelos (Welch test p-value = 0.000445).

É no comportamento dos agentes D que a formação de grupos tem mais efeito. Os agentes D começam a simulação com comportamento aleatório e a partir da rodada 90 se inicia um crescimento da cooperação atingindo uma média de 6,21 horas de caça em média na

rodada 500 ($DP = 0,76$), valor maior que as 6,03 horas de caça em média no mesmo período do modelo sem formação de grupos.

A partir daqui a tendência muda. Enquanto que no modelo sem formação de grupos houve uma queda forte nos valores de horas de caça a partir da rodada 500, no modelo com formação de grupos, a queda é bem mais suave, e não é capaz de reverter a cooperação dos agentes. Na rodada 2000, os agentes D decidiram caçar durante 5,87 horas em média ($DP = 1,49$, $IC = [5,44; 6,29]$).

Ou seja, enquanto que no modelo somente com seleção os agentes D se tornam mais egoístas, no modelo com seleção e formação de grupos eles se tornam mais cooperativos.

Resumindo, o efeito da formação de grupos partindo de um modelo somente com seleção é de aumentar a cooperação entre os agentes. Além disso, também não se pode aceitar que existe uma correlação entre as decisões de horas de caça e percentual de divisão do resultado da caça (Pearson p-value = 0,4507) como no modelo sem a formação de grupos.

Por último, analisando o efeito da formação de grupos no modelo com aprendizado e seleção, verifica-se que neste caso ela também tem o efeito de aumentar a cooperação entre os agentes.

O comportamento dos agentes M inicia de forma aleatória e logo se torna mais egoísta, atingindo um percentual de divisão da caça de 13,6% na rodada 2000 ($DP = 5,2\%$). Esse valor é bem maior que os 4,2% em média obtidos no modelo sem formação de grupos.

O comportamento dos agentes D também se inicia de forma aleatória e atinge 6,07 horas de caça em média na rodada 500 ($DP = 0,63$), a partir de quando apresenta uma leve queda chegando a 5,69 horas de caça em média na rodada 2000 ($DP = 0,71$). Esse valor também é maior que as 5,14 horas de caça observadas no modelo sem formação de grupos. Pelo teste de diferença (Welch test p-value = 0,0002486), pode-se aceitar que o comportamento dos agentes D diferem nos dois modelos.

Outra mudança interessante é que a correlação entre horas de caça e percentual de divisão da caça que existia no modelo sem formação de grupos deixa de ser significativa no modelo com formação de grupos (Pearson p-value = 0,08939).

Outra forma de se analisar o modelo com aprendizado, seleção e formação de grupos seria compará-lo com o modelo com seleção e formação de grupos e verificar o impacto que o aprendizado gera no modelo. Conforme visto anteriormente, esses dois modelos não apresentam correlação significativa entre horas de caça e percentual de divisão da caça. Resta saber se o aprendizado favorece ou não a cooperação entre os agentes.

Olhando os resultados de percentual de divisão da caça na rodada 2000, o aprendizado faz com que esse número passe de 9,0% (DP = 10,9%) para 13,6% (DP = 5,2%). Essa diferença é significativa (Welch test p-value = 0,008806) e pode-se aceitar que o aprendizado aumenta a cooperação dos agentes M.

O mesmo não se pode afirmar com relação ao comportamento dos agentes D. A média das horas de caça na rodada 2000 caem um pouco com o aprendizado, passando de 5,87 (DP = 1,49) para 5,69 (DP = 0,71), porém essa diferença não é significativa (Welch test p-value = 0,4586).

Portanto, pode-se afirmar que o aprendizado aumenta a cooperação dos agentes M em modelos com seleção e formação de grupos e não chega a afetar o comportamento dos agentes D. Vale notar que o aprendizado reduz a dispersão do comportamento entre as várias simulações do modelo.

5.5. VALIDAÇÃO COM DADOS REAIS

Conforme mencionado na seção 4, modelos de simulação baseado em agentes ajudam a entender as propriedades de sistemas complexos. De forma complementar aos experimentos, este modelo de simulação permitiu analisar fatores que dificilmente seriam explorados em experimentos, como os vistos nas subseções anteriores. É necessário, porém, que o modelo seja validado com as informações obtidas nos experimentos para que essa análise seja relevante. Dessa forma, o modelo representa escolhas semelhantes às dos indivíduos no experimento proposto por Berg, Dickhaut e McCabe (1995). Isso permite que se possam analisar os resultados das simulações e verificar o quanto eles se aproximam dos resultados obtidos pelos experimentos.

No trabalho de Berg, Dickhaut e McCabe (1995) foram feitos dois tipos de experimentos com jogos do investimento, um sem história social, onde os jogadores não receberam nenhuma informação a respeito do histórico de decisão de experimentos anteriores, e outro com história social, onde os jogadores receberam um resumo dos resultados dos experimentos sem história social, como a quantidade de indivíduos por valor investido, o valor médio retornado e o valor médio de lucro (valor médio retornado menos o valor médio enviado). A tabela 1 mostra os resultados obtidos nos experimentos publicados no artigo. Cada coluna se refere a uma rodada do experimento. Foram feitas três rodadas sem história social e três rodadas com história social. Cada par se refere ao resultado de uma dupla, sendo

o primeiro número, o valor enviado e o segundo o valor retornado. Esses dados possibilitam que se faça uma análise do quanto eles se aproximam dos resultados obtidos nas simulações.

Nos experimentos sem história social a média de valores enviados pelos Investidores foi de \$ 5,16 (DP = \$ 2,94) e a média do percentual retornado pelos Parceiros foi de 28,0% (DP = 28,6%). Ao se comparar a decisão dos Investidores do jogo de confiança com a decisão dos agentes Direcionadores do modelo com aprendizado, seleção e formação de grupos (5,69 horas de caça, DP = 0,71), pode-se aceitar que a diferença entre eles não é significativa (Welch test p-value = 0,318). Porém, ao se comparar a decisão dos Parceiros com a decisão dos agentes Matadores (13,6% de divisão da caça, DP = 5,2%), a diferença passa a ser significativa (Welch test p-value = 0,008486).

O mesmo se pode observar ao se fazer a comparação com os experimentos com história social. Pode-se aceitar que a diferença entre os valores enviados pelos Investidores (\$ 5,36, DP = \$ 3,53) e as decisões dos agentes D no modelo com aprendizado, seleção e formação de grupos não é significativa (Welch test p-value = 0,6224). Mas a diferença entre o percentual retornado pelos Parceiros (33,1%, DP = 26,2%) e as decisões dos agentes M é significativa (Welch test p-value = 0,000546).

Tabela 1 – Resultados dos experimentos com jogos do investimento em pares ordenados (Investimento, Retorno)

	Sem história social			Com história social		
1	(7,1)	(5,7)	(6,12)	(5,11)	(3,0)	(1,1)
2	(3,0)	(10,0)	(10,15)	(10,15)	(2,0)	(10,20)
3	(7,6)	(5,0)	(3,6)	(2,2)	(10,5)	(7,14)
4	(5,11)	(8,4)	(6,8)	(5,8)	(2,0)	(10,15)
5	(3,1)	(5,15)	(6,1)	(0,0)	(5,0)	(3,6)
6	(2,4)	(0,0)	(10,15)	(2,1)	(5,10)	(10,10)
7	(6,0)	(7,1)	(10,1)	(10,16)	(8,3)	(6,8)
8	(4,1)	(1,0)	(6,3)	(10,15)	(5,8)	(5,8)
9	(10,20)	(3,5)	(4,1)	(5,5)	(0,0)	(0,0)
10	(5,5)	(2,0)	(0,0)	(9,0)		
11			(5,5)			
12			(1,1)			

Fonte: Berg, Dickhaut e McCabe (1995).

Como não há correlação entre as decisões dos agentes D e M no modelo, é possível afirmar que a modelagem da forma como ela está reflete o comportamento dos agentes D como ela ocorre em experimentos reais. Porém, para os agentes M, seria necessário desenvolver outro mecanismo no modelo de simulação que pudesse aumentar a reciprocidade e tornar o comportamento desses agentes mais parecidos com o que observamos na realidade.

6. CONCLUSÕES

A teoria dos jogos tradicional, ao assumir que os jogadores são egoístas e maximizadores, não prevê a existência de confiança em transações que garantam o anonimato entre os agentes e nas quais não haja possibilidade de se formar reputação. Porém, ao se analisar essas transações através de experimentos, pode-se verificar que as pessoas agem de forma a confiar umas nas outras, mesmo sob tais condições.

Na literatura, geralmente usam-se funções de utilidade que incorporam os resultados de outros jogadores para que se chegue aos mesmos resultados dos experimentos. Assim, alguns comportamentos como aversão a desigualdades e senso de justiça podem ser incorporados à teoria ao mesmo tempo em que fazem com que a teoria passe a refletir os resultados empíricos observados em experimentos com jogos.

Porém, é importante também que haja uma discussão a respeito de como essas dinâmicas sociais podem surgir a princípio. Se os indivíduos são influenciados por dinâmicas sociais que guiam suas ações de forma a mudar suas funções de utilidade, resta saber se há mecanismos que fazem com que essas dinâmicas possam emergir espontaneamente da interação entre os indivíduos.

O desafio que surge nesse caso seria como desenhar um processo de decisão que permita que as decisões dos indivíduos surjam com base no seu uso. Dinâmicas sociais, como normas sociais, surgiriam, portanto de práticas que se tornam comum pelo seu uso habitual. E o hábito se forma de acordo com o uso mais conveniente por meio de um processo evolutivo. Sábias decisões se perpetuam.

Uma das contribuições dessa dissertação é a proposta de modelar as decisões num processo evolutivo que também reflete a forma como os indivíduos tomam decisões de fato. Ao usar o LCS é possível ao mesmo tempo usar uma modelagem que reflete o raciocínio humano, pela sua proximidade com a teoria da racionalidade limitada, como também não definir previamente quais premissas são responsáveis pelos processos de decisão que se formam. É através da própria evolução do processo de decisão que essas decisões são formadas.

A estratégia escolhida neste trabalho foi, utilizando a ideia de modelos generativos de Epstein e Axtell (1996), montar um modelo de simulação com regras aleatórias de decisão por busca por alimento: a coleta de frutas como uma atividade individual e a caça de javali como uma atividade em dupla. A primeira gera menos calorias que a segunda que, no entanto, requer a confiança de um dos participantes. Com base nesse modelo mais simples, foram

introduzidos alguns fatores, a saber, aprendizado, seleção natural e formação de grupos e seu impacto individual e conjunto na emergência da confiança foram analisados.

Esses três fatores não são premissas utilizadas no desenho dos mesmos e sim mecanismos pelos quais essas decisões vão se adaptando e vão sendo formadas. Para exemplificar, podemos ter dois tipos de modelos: o primeiro seria um com regras de decisão que sejam desenhadas para refletirem as dinâmicas sociais e com resultados em conformidade com as evidências empíricas. O segundo seria um modelo com mecanismos de adaptação e evolução que seriam responsáveis para que, aos poucos o conjunto tenha mais decisões em conformidade com essas dinâmicas sociais. Essa dissertação é um exemplo do segundo tipo.

A análise dos resultados obtidos mostrou que dos três fatores analisados, a seleção natural tende a favorecer decisões mais maximizadoras e egoístas, enquanto que o aprendizado e a formação de grupos, quando atua junto com a seleção natural, favorecem comportamentos mais cooperativos.

Ao comparar o modelo com os três fatores com os dados obtidos dos experimentos, pode-se aceitar que a diferença do comportamento médio dos agentes em relação à confiança não é diferente entre eles. Porém, há diferença em relação à reciprocidade, com os agentes do modelo de simulação sendo mais egoístas em média que os agentes do experimento.

Como não há correlação significativa entre confiança e reciprocidade tanto no modelo como nos dados obtidos nos experimentos, pode-se afirmar que um modelo de simulação onde haja aprendizado dos agentes, seleção natural e formação de grupos consegue modelar a confiança observada em experimentos com jogos de investimento. Já a reciprocidade não pode ser modelada dessa forma exigindo um aprofundamento maior na modelagem.

É possível argumentar que o desenho do modelo pode favorecer a emergência da confiança por parte dos Direcionadores. Como o jogo é repetitivo e os papéis são definidos de forma aleatória, vale a pena que uma população tenha agentes D cooperativos que aumentem o montante adquirido mesmo quando agentes M não corresponderem, pois numa rodada futura ele tem chance de ser agente M e receber um montante maior e agir de forma egoísta. A comparação com o experimento fica prejudicada, pois nele foi feita apenas uma jogada e o desenho do experimento não permitia essa dinâmica.

É nesse aspecto que o estudo das dinâmicas sociais e sua influência no processo de decisão dos indivíduos nos experimentos é importante. As regras de decisão dos indivíduos são formadas antes da participação deles nos experimentos. Sendo assim, o jogo é só mais uma interação entre outras, não necessariamente com o mesmo desenho, mas com características similares, que permitiram que aos poucos os indivíduos incorporassem as

dinâmicas sociais e formassem suas regras de decisão que serão utilizadas em situações análogas.

Estudar a emergência da confiança através da simulação baseada em agentes não é um processo substituto ao estudo de como alterar as funções de utilidade e sim um trabalho complementar.

Um futuro trabalho pode explorar outros fatores que façam com que o nível de reciprocidade observado no modelo seja compatível com o observado nos experimentos. Esse parâmetro pode estar relacionado com a avaliação das regras de reciprocidade. Além disso, o trabalho feito aqui pode ser estendido ao incorporar outras questões que são importantes na emergência da confiança e que não foram exploradas como a formação de reputação e a comunicação entre os agentes. Outra extensão dessa pesquisa consiste em analisar as regras que foram mais bem sucedidas em tornar os agentes mais abastados e, com isso entender que reflexões podemos tirar dessas estratégias para melhorar nossa própria qualidade de vida.

Essas extensões da pesquisa podem ajudar a elaborar políticas que, por exemplo, poderiam aumentar a colaboração entre pessoas ao compartilhar seus bens com outras dentro da Economia Compartilhada, tema de grande importância como política para diminuir o impacto ambiental da atividade humana sem diminuir a qualidade de vida das pessoas.

REFERÊNCIAS

- ARROW, Kenneth. *Gifts and Exchanges*. Philosophy and Public Affairs, I (1972), 343-362.
- AXELROD, Robert. *The complexity of cooperation : agent-based models of competition and collaboration*. Princeton University Press
- BAPNA, Ravi; GUPTA, Alok; RICE, Sarah; SUNDARARAJAN, Arun. *Trust, Reciprocity and the Strength of Social Ties: An Online Social Network based Field Experiment*.
- BERG, Joyce; DICKHAUT, John; MCCABE, Kevin. *Trust, Reciprocity and Social History*. Games and Economic Behavior 10 (1995) 122–142.
- BESTER, Helmut; GÜTH, Werner. *Is altruism evolutionarily stable?* Journal of Economic Behavior & Organization, Vol. 34 (1998) 193-209.
- CAMERER, C. (2003). *Behavioral Game Theory: Experiments in Strategic Interaction*. Princeton University Press, Princeton.
- COLEMAN, James. *Social Capital in the Creation of Human Capital*. American Journal of Sociology, Vol. 94, Supplement: Organizations and Institutions: Sociological and Economic Approaches to the Analysis of Social Structure (1988), pp. S95-S120. The University of Chicago Press.
- COX, James C. *How to identify trust and*. Games and Economic Behavior 46 (2004) 260–281
- EPSTEIN, Joshua M.; AXTELL, Robert. (1996). *Growing Artificial Societies: Social Science from the Bottom Up*.
- FUKUYAMA, Francis (1995). *Trust: The social virtues and the creation of prosperity*. Free Press Paperbacks.
- HARTFORD, Tim (2006). *The Economics of Trust*. Forbes. Disponível em: https://www.forbes.com/2006/09/22/trust-economy-markets-tech_cx_th_06trust_0925harford.html
- HOLLAND, J. H. (1975) *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor.
- HOLLAND, J. H. (1996). *Hidden Order: How Adaptation Builds Complexity*. Helix Books, Reading, MA
- KAHNEMAN, Daniel; KNETSCH, Jack L.; THALER, Richard H. *Fairness and the Assumptions of Economics*. The Journal of Business, Vol. 59, No. 4, Part 2: The Behavioral Foundations of Economic Theory (Oct., 1986), pp. S285-S300
- KARLAN, Dean; MOBIUS, Markus; ROSENBLAT, Tanya; SZEIDL, Adam. *Trust and Social Collateral*. The Quarterly Journal of Economics, Vol. 124, No. 3, pp. 1307-1361. Oxford University Press, 2009.

KNACK, Stephen; KEEFER, Philip. *Does Social Capital Have an Economic Payoff? A Cross-Country Investigation*. The Quarterly Journal of Economics, Vol. 112, No. 4, pp. 1251-1288. Oxford University Press, 1997.

LIPPERT, Steffen; SPAGNOLO, Giancarlo. *Networks of relations and Word-of-Mouth Communication*. Games and Economic Behavior 72 (2011) 202–217.

MACY, Michael W.; SKVORETZ, John. *The Evolution of Trust and Cooperation between Strangers: A Computational Model*. American Sociological Review, Vol. 63, No. 5 (Oct., 1998), pp. 638-660

MANAPAT, Michael L.; NOWAK, Martin A.; RAND, David G. *Information, Irrationality, and the Evolution of Trust*. Journal of Economic Behavior & Organization 90S (2013) S57–S75.

RAND, David G.; TARNITA, Corina E.; OHTSUKI, Hisashi; NOWAK, Martin A.. *Evolution of fairness in the one-shot anonymous Ultimatum Game*. PNAS, February 2013, vol. 110, no. 7, 2581–2586.

SIMON, H. A. *Theories of Decision Making in Economics and Behavioral Science*. The American Economic Review, Vol. 49, No 3 (Jun, 1959), pp. 253-283.

SIMON, Herbert A. *Rationality as Process and as Product of Thought*. The American Economic Review, Vol. 68, No. 2, Papers and Proceedings of the Ninetieth Annual Meeting of the American Economic Association (May, 1978), pp. 1-16.

SIMON, H. A. *Rational Decision Making in Business Organizations*. The American Economic Review, Vol. 69, No 4 (Set, 1979), pp. 493-513.

TESFATSION, L. (2005) *Agent-Based Computational Economics: A Constructive Approach to Economic Theory*.

VAN DIJK, Frans; SONNEMANS, Joep; VAN WINDEN, Frans. *Social ties in a public good experiment*. Journal of Public Economics 85 (2002) 275–299.

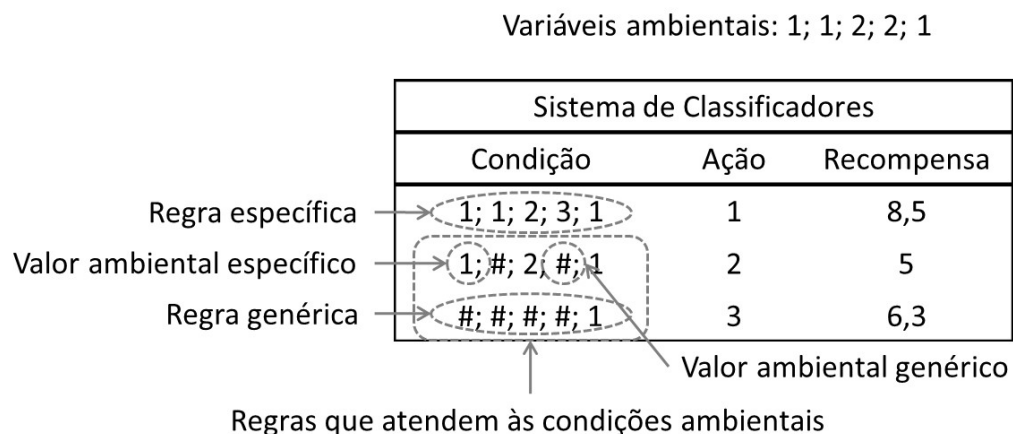
WILSON, J.; HILL, J.; KERSULA, M.; WILSON, C. L.; WHITSEL, L.; YAN, L.; ACHERSON, J.; CHEN, Y.; CLEAVER C.; CONGDON, C.; HAYDEN, A.; HAYES, P.; JOHNSON, T.; MOREHEAD, G.; STENECK, R.; TURNER, R.; VADAS, R.; WILSON, C. J. *Costly Information and the Evolution of Self-organization in a Small, Complex Economy*. Journal of Economic Behavior & Organization 90S (2013) S76–S93.

WILSON, David S.; WILSON, Edward O. *Rethinking the Theoretical Foundation of Sociobiology*. The Quarterly Review of Biology, December 2007, Vol. 82, No. 4, pp. 327-348.

APÊNDICE I – ALGORITMO LEARNING CLASSIFIER SYSTEM (LCS)

Um classificador ou regra de decisão dentro do LCS associa uma condição ambiental a uma ação em particular. Essa regra também está associada a uma recompensa. Um sistema de classificadores é composto de várias dessas regras que mapeiam várias condições ambientais a várias ações, cada uma com um determinado valor de recompensa. Cada item da condição pode ser um valor específico de uma variável do ambiente ou um valor genérico que pode corresponder a qualquer condição ambiental daquela variável. Dessa forma, se uma condição tem muitos valores específicos, a regra só será aplicada a condições ambientais muito restritas. Caso a regra tenha muitos valores genéricos, ela poderá ser aplicada a uma variedade maior de situações. A figura 4 exemplifica um sistema de classificadores.

Figura 4 - Exemplo de um sistema de classificadores



Nota: Cada valor dentro de uma condição corresponde a uma variável ambiental. O caractere # representa um valor genérico, ou "tanto faz", que corresponde a qualquer condição ambiental. Uma regra com poucos # é mais específica, já uma regra com mais # é mais genérica. Nesse exemplo, as duas últimas regras são as que atendem à condição ambiental.

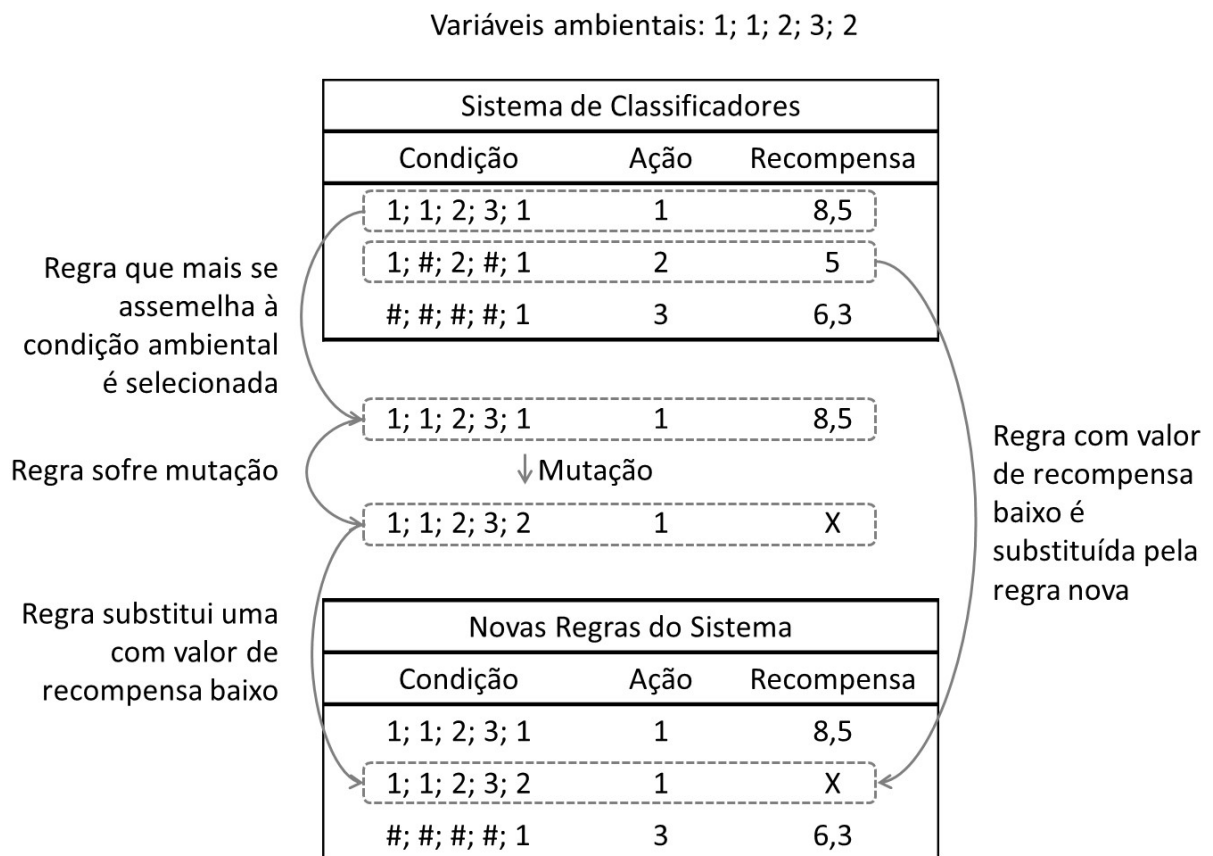
Fonte: Baseado em Wilson et al (2013).

Dada uma condição ambiental, o LCS seleciona as regras que atendem a essa condição, escolhe dentre essas a que tem o maior valor de recompensa e executa a ação correspondente a essa regra. O LCS é um sistema adaptativo e uma das suas principais características é o aprendizado pelo reforço (*reinforcement learning*). Sendo assim, após a execução de uma ação o sistema apura as consequências dessa ação e atribui um valor de recompensa pela ação desempenhada. Se a ação teve um desempenho bom, a regra aumenta seu valor de recompensa e, consequentemente aumentam as chances de a regra ser usada

novamente no futuro. Caso contrário, seu valor diminui e seu uso acaba sendo cada vez menos frequente.

A ação executada pelo indivíduo após o processo de decisão tem impacto no ambiente alterando as variáveis ambientais. Numa próxima rodada, um novo conjunto de regras poderá atender à nova condição ambiental e outra regra poderá ser selecionada. Caso nenhuma regra atenda à condição ambiental, o sistema seleciona uma regra que mais se assemelha à condição ambiental e ela sofre uma mutação de forma a atender essa nova condição. Essa regra passa a fazer parte do sistema de classificadores substituindo uma regra existente que tenha baixo valor de recompensa. A figura 5 exemplifica esse processo.

Figura 5 - Criação de regra nova quando não há regras que atendam a condição ambiental



Nota: Caso nenhuma regra atenda à condição ambiental, uma regra mais próxima à condição sofre uma mutação e substitui uma regra com pouco baixo valor de recompensa.

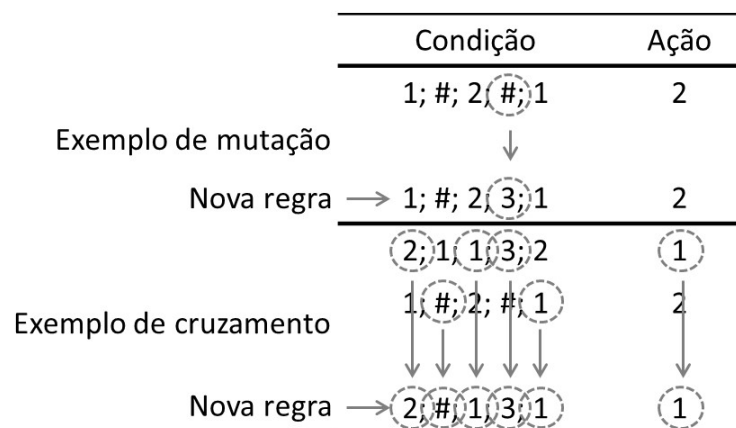
Fonte: Baseado em Wilson et al (2013).

Além do processo de *reinforcement learning*, o LCS também usa um algoritmo genético para que o agente possa testar novas possibilidades de ações através da criação de novas regras. Essas novas regras são criadas através de um processo de mutação ou de um processo de cruzamento.

O processo de mutação seleciona uma regra aleatoriamente com probabilidade proporcional ao seu valor de recompensa, ou seja, regras mais adaptadas ou mais fortes são selecionadas com maior chance. Essa regra sofre uma mutação em um dos valores da condição ou da ação, criando assim uma nova regra que substitui uma regra existente. Essa regra a ser substituída é selecionada aleatoriamente também, porém com probabilidade inversamente proporcional ao seu valor de recompensa. Ou seja, regras mais fracas ou menos adaptadas são substituídas com maior frequência.

Já o processo de cruzamento seleciona duas regras aleatoriamente com probabilidade proporcional ao seu valor de recompensa e cria uma nova regra com valores e ações provenientes das duas regras originais. De forma análoga ao processo de mutação, essa nova regra substitui uma regra existente selecionada com probabilidade inversamente proporcional ao seu valor de recompensa. A figura 6 mostra como funcionam os processos de mutação e de cruzamento.

Figura 6 – Exemplo de processos de mutação e cruzamento de regras



Fonte: Baseado em Wilson et al (2013).